エージェント・シミュレーションによる 農作物作付け品目選択モデルの検討

Modeling farmer’s planting using MAS

軽部 勲 [1]　倉橋 節也 [1]

Isao KARUBE[1], Setsuya KURAHASHI[1]

[1] 筑波大学
[1]University of Tsukuba

Abstract: Japanese agricultural sector is facing several risks such as "the aging farming population", "the shortage of successors”, “the increasing abandoned farmland” and “low profitability ". Japanese government and farmers have been deploying various efforts to eliminate these risks such as changing The Agricultural Land Act and investing Infrastructure investment. There are cases of improving sales by constructing new irrigation facilities and developing means of transportation and sales channels. In this paper, authors made simple plant selection models of farmers and governments and try to check the impact to planting of farmers by MAS (multi agent simulation).

1. はじめに

近年，日本の農業分野では高齢化や担い手不足に伴う耕作放棄地の増加により，生産量が低下している[1]．政府や自治体では農作物の生産量や売上を向上させるために様々な施策を講じている．主な施策として

・農業法人参入障壁の低減を目指した農地法改正
・生産者維持を目的とした補助金
・生産，販売の増加を目的としたインフラ投資

などが実施されている．

これらの施策の中でも，インフラ投資の例として新たな灌漑施設を構築したり輸送手段や販路を開拓したりすることにより大きく売上を向上させる事例が見受けられる．筆者らはこれらの施策に伴う作付け品目の選択の変化に着目，作付け品目選択モデルを構築してエージェント･シミュレーションを用い，新たな施策の影響度を推定することを目的とした検討を進めている．本報告では，最初のステップとして作付け品目選択モデルの構築と，モデルに基いたエージェント・シミュレーション環境の構築結果について述べる．

2. 先行研究

農業経営にエージェントモデルを適用した例としては文献[2, 3, 4, 5]などが挙げられる．文献[3] では集落営農の組織化の効果予測を目的として，集落営農の規模拡大を想定した営農組合の統合シミュレーションを実施しており，集落営農を組織化することで，労働力・機械を集約，経営の持続性を高めることができる，という結果が報告されている．

また，文献[5]では小規模の農業生産者の経営統合による影響が報告されている．文献[6]では仮想的な社会において，農業参入企業の集落に与える影響が報告されている．このように先行研究では政府や自治体が進めている，農業法人の参入障壁を低くする取り組みに関連して経営統合や企業参入の影響をMAS により検証を実施している．

本研究では政府や自治体や自治体が進めるほかの施策である，補助金，インフラ投資の影響をエージェントモデルにて検証することを目標とする．

3. エージェントモデルの検討

通常，生産者は行政の補助金やインフラ投資に従って作付け品目を変化させ, 収入を増やそうとする．また，行政は生産者の収入を確保し，生産量の維持を図るために予算を配分する．

本研究では，農業生産者の作付け品目選択モデルを作成，行政の投資に応じてどのように作付け品目が変化するか，シミュレーションを用いて評価する方針とした．モデル化された作付け品目の販売を通して得られた生産者の収入を見て，行政は次年度の

投資を判断することとした．

今回行政側の投資項目として使用する項目を Table1 に示す．補助金の投資は生産者を維持するために生産量に応じて給付するものであり，例えばサトウキビでは補助金の割合が多くを占める (1t 当たりの売買価格は約 6,000 円に対し補助金約 16,000 円を支給，など)．また，空港建設などの販路投資は販売を増大するためのものであり，例えば離島などでは販路を拡大により都市部への販路が開け，生産者の売上が大幅に伸びた例などがある．灌漑投資は，生産者の灌漑用水確保のコストを下げることができ，生産量も向上させる効果がある．

Table 1　行政の投資項目

項目	目的
補助金	生産農家数維持
販路投資	販路拡大
灌漑投資	生産量増加

生産者は補助金や販路の状況に応じて作付け品目の選択を行うこととする．今回は各年度における行政の投資先と作付け品目を状態とし，生産者は Fig. 1 に示すような 2 品目の作付けを選択することとした．生産者のモデルに利用する主なパラメータを Table2 に示す．作付け品目は補助金が大きな割合を占めるサトウキビと，販路が拡大すると売り上げが大幅に伸びる果樹から選択することとした．収入は生産した作物の売上の他，補助金による収入を想定している．コストについては生産コストと，作付け品目を変更する場合の移行コストを想定した．

また，補助金は生産物販売の収入に対する割合，灌漑は用水確保のコスト削減割合と水量増加による生産量増加割合，販路による販路拡大は生産物の販売増加の割合として表現した．

これらのパラメータを利用して，行政の投資による効果を検証する．

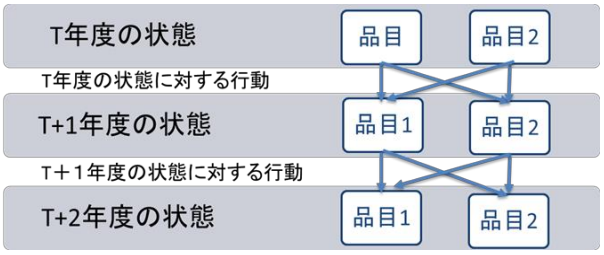

Fig. 1 農作物作付け品目における状態と行動定義例

Ttable2　生産者モデルに利用する主なパラメータ

パラメータ	概要
作付品目	サトウキビ，果樹
収入	生産物の販売，及び補助金による収入
コスト	生産コスト，作付け品目変更コスト
販売確率	販路拡大に伴う販売増加の割合
灌漑影響率①	灌漑は用水確保のコスト削減割合
灌漑影響率②	水量増加による生産量増加割合
補助金率	生産物価格に対する補助金の割合

3. 強化学習を適用したシミュレーション生成検討

行政の投資効果の検証手法として，本研究では強化学習を用いた．強化学習は環境のダイナミクスが未知の場合でも適用可能であることが特徴である．

ここでは，行政の投資を，行動と定義し，生産者の作付け品目選択をモデル化，生産により得た収入を報酬として政府の判断に反映させることとした．Table3 に行政の投資行動とその内容を示す．投資行動による影響は Table3 のように作物により異なる設定とした．

Table3　行政の投資行動種類

行動	影響
補助金	サトウキビを対象に生産量に応じた補填
販路投資	販路など販路の整備による果樹の販売確率増大
灌漑投資	灌漑用水整備によるサトウキビの生産量増加 用水取得コスト削減

また，Table4 に行動に対する状態を示す．状態は年毎の生産者の作付け品目と行政の投資結果で表現することとした．

これらの行動と状態について Q 学習を適用したシミュレーションを実施した[6]．各作付け品目に対する項目とその設定値の例を Table5 に示す．収入，生産コスト，補助金，多品目切替コストは金額，販売数は各々の生産物の販売数を示し，それ以外は各項目の収入，コストに占める割合を各坑道の有無の場合で示している．

Table4　行政，生産者含めた状態の分類

作付け品目	投資対象	対象年度
サトウキビ	補助金	設定された年度分
	灌漑	設定された年度分
	販路	設定された年度分
果樹	補助金	設定された年度分
	灌漑	設定された年度分
	販路	設定された年度分

Table5　各作付け品目に対する項目とその設定値例

項目	サトウキビ	果樹
収入	50	100
生産コスト	10	30
補助金 (補助あり/なし)	200/100	0
販売数 (販路あり/なし)	100	70 /140
単価上昇率[%] (販路あり/なし)	0	50/0
灌漑コスト削減率[%] (灌漑あり/なし)	-50/0	-20/0
灌漑収益向上率[%] (灌漑あり/なし)	20/0	0
他品目切替コスト	50	20

3. シミュレーション結果

3 章にて検討した強化学習をエージェントモデルとして実装した．Fig.1 に実装した MAS のシミュレーション画面を示す．

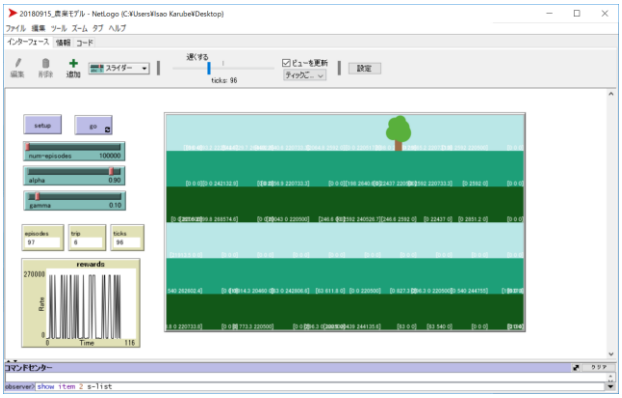

Fig.1 MAS 実装画面

ここで, 画面内右側のフィールドエリアは 10 年間の状態を示しており，上部 3 行は果実，下部 3 行はサトウキビを示している．このような環境で，Q 学習を実施した. シミュレーションでは, 最初の 10,000 回はランダムな行動選択，その後 Q 値によるルーレット選択とした．Fig.2 に 10 年間のシミュレーションを 10 万回実施した結果を示す．1 万回の試行で Q 値が設定された後報酬の高い行動が選択されていることがわかる．また，学習の結果，報酬の高い行動として販路拡大への投資が選択され，生産者側は果樹の選択確率が大幅に増加した．

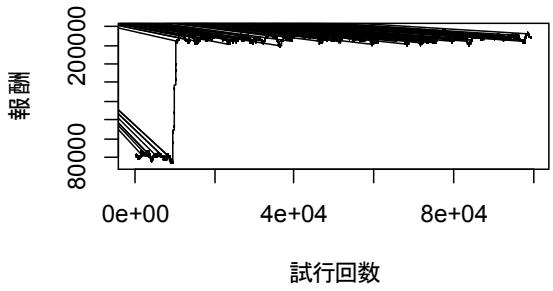

Fig.2 シミュレーション結果

4. まとめと今後の課題

国や自治体の農業への投資とその作付け品目への影響についてシンプルな作付け品目選択モデルを構築，強化学習を用いたシミュレーションにて傾向を確認した．今回は学習の手法として Q 学習を利用したが，販路や灌漑の投資は建設までに多額の費用を投じ，その後長期間にわたり回収するモデルとなる場合が想定され，今回適用した手法が必ずしも適しているとはは言えない．今後はモンテカルロ法など他の手法についても検討する．また，今後は実データを利用した，より精緻なしミューレションが可能か，検討を進める．

参考文献

[1] 農林水産省: 農村の現状に関する統計, (2017) http://www.maff.go.jp/j/tokei/sihyo/data/12.html
[2] 山下 良平,星野 敏: マルチエージェントシミュレーションによる集落営農計画モデルの開発, 農村計画学会誌, Vol24, No2, 104-114, (2005)
[3] 山下 良平, 星野 敏: 営農組合の経営統合に関する効果比較シミュレー ション, 農林業問題研究, 42(1), 89-94, (2006)
[4] 山下 良平: マルチエージェントシミュレーションによる調和を維持した農業参入企業の地域定着条件の解明, 平成 22 年度国土政策関係研究支援事業　研究成果報告書, (2010)
[5] 星野 敏, 山下 良平: マルチエージェント・シミュレーションによる地域農業計画モデルの可能性, ARIC 情報 No87-2007, (2007)
[6] Richard S. Sutton, Andrew G. Barto : Reinforcement Learning: An Introduction,　(2017)

カバー先銀行の集合知による外国為替レート予測

Prediction of Foreign Exchange Rates by Collective Intelligence of Counter Party Banks

鈴木 丈裕 [1] *　　鈴木 智也 [1,2]
Takehiro SUZUKI[1]　　Tomoya SUZUKI[1,2]

[1] 茨城大学大学院理工学研究科
[1] Graduate School of Science and Engineering, Ibaraki University
[2] コラボウィズ株式会社
[2] CollabWiz, Inc.

Abstract: In foreign-exchange (FX) dealing, FX brokers basically cancel out the orders from their customers to prevent the price fluctuation risk by cover transactions with global megabanks called Counter Party (CP). Each CP has huge amount of money to play a role of market reader, and might have proprietary know-how to foresee future price movements. From this viewpoint, we try to extract their knowledge by a machine learning approach, and therefore we apply the stacking method that aggregates some predictors to extract the ensemble knowledge. If CP's price quotations are decided by foreseeing future price possibilities, their quotations can be considered as predictors. From this concept, we apply the stacking method to their quotations and obtain the ensemble knowledge from them. Through some simulations using real price data, we could confirm that the given ensemble knowledge improves the prediction accuracy of FX price movements compared to the machine learning using a single CP's price quotation.

1　はじめに

外国為替証拠金取引 (Foreign Exchange: FX) において，店頭外国為替証拠金取引取扱業者 (以下，FX 業者) は顧客と各国の通貨間の売買を行う際に，価格変動に伴う損失のリスクを減らすカバー取引を銀行と行う．これらのカバー先銀行をカウンターパーティ(Counter Party: CP) と呼び，FX 業者は CP から送信される各通貨間の Bid(売値) と Ask(買値) の為替レート建値 (為替相場で銀行が公表する取引価格) に基づいて顧客に提示する自社のレートを生成している．このとき CP から送信される為替レート建値を CP レート，顧客に提示する自社のレートをハウスレートと呼ぶ．ここで CP からレートを受信する構造上，ハウスレート生成に低遅延が発生する．このような受信による遅延やシステム障害による遅延により他の FX 業者と大きく異なるレートを提示してしまった場合，業者間裁定取引者 (各業者間のハウスレートの価格差を利用して収益を上げる顧客) のターゲットにされる怖れがある．ここで FX 業者が極短時間後の CP レートを予測し，この遅延を低減できれば，収益の悪化を抑制できる．さらにレート更新の早さは，市況情報に対する正確性から顧客を多く獲得でき，他の FX 業者との競争において有利になるメリットもある．これらの観点から，CP レートの将来価格を予測することは FX 業者の収益獲得に繋がる可能性がある．

ここで将来価格の予測に関して，カバー先である CP に着眼する．各 CP 同士は収益獲得競争のため相場をある程度先読みして CP レートを生成しており，CP ごとに様々なノウハウを有している可能性がある．そこで本研究では FX 業者の立場になり [1]，各 CP の建値情報 [2] をアンサンブル学習の一種であるスタッキング [3] の概念を用いて集合知 [4–7] を抽出する．この集合知を用いることで効率的市場仮説 [8] によってランダムウォークのように予測不可能とされる為替変動に対して，どの程度予測力を高められるか検証する．

2　スタッキングによる集合知の獲得

まず一般的なスタッキングを図 1 に示す．共通のオリジナルデータを用いて複数の異なる予測モデルを学習し，それらが出力した予測値に対して新たに別の予

*連絡先：茨城大学大学院理工学研究科知能システム工学専攻
〒 316–8511 茨城県日立市中成沢町 4–12–1
E-mail: 17nm926l@vc.ibaraki.ac.jp

測モデルでメタ学習することで，最終的な予測値を得る [9]．これに対して本研究では図 2 に示すように，共通のオリジナルデータを全世界の市況情報と見立てて，ノウハウを有する各 CP を予測器と考える．これらをニューラルネットワークでメタ学習することで，各 CP のノウハウを統合した集合知を獲得する．この集合知が最終的な予測値として機能するのか確認するため，CP 毎の建値情報のみを機械学習する予測モデル (個別法) とスタッキングの概念を応用した提案法を比較する．

集合知の効果を示す一例として多様性予測定理 [10] を紹介する．各予測モデルから得られる予測値の分散 (多様性) が大きいほど集合知の予測誤差が縮小することが知られている．全 N 個の予測モデルにおいて，第 i 番目のモデルによる個別の予測値を $\hat{y}_i$，これらを統合した集合知による予測値を $E[\hat{y}] = \frac{1}{N}\sum_{i=1}^{N}\hat{y}_i$，真値を y とすると，以下の等式が成立する．

$$(y - E[\hat{y}])^2 = \frac{1}{N}\sum_{i=1}^{N}(y - \hat{y}_i)^2 - \frac{1}{N}\sum_{i=1}^{N}(\hat{y}_i - E[\hat{y}])^2 \quad (1)$$

ここで左辺は集合知の予測誤差，右辺第 1 項は各予測モデルの平均予測誤差，右辺第 2 項は予測モデルの分散値に相当する．つまり多様な CP の建値情報を統合することで互いの不正確な予測を打ち消し合うことで集合知を獲得し，右辺第 2 項のような誤差低減効果を期待できる．

補足として，説明変数に用いる CP および通貨ペアを増やすほど機械学習に伴う入力次元数が増加するため，Deep Neural Network [11] が効果的であろう．しかし本稿の設定 (次章) では比較的低次元であるため，通常の 3 層ニューラルネットワークを用いる．

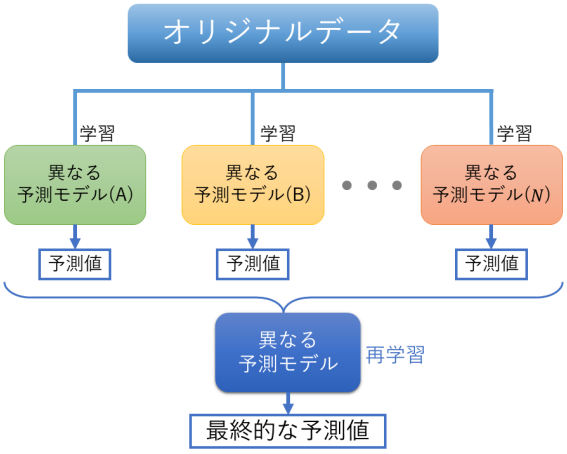

図 1: 一般的なスタッキングの例

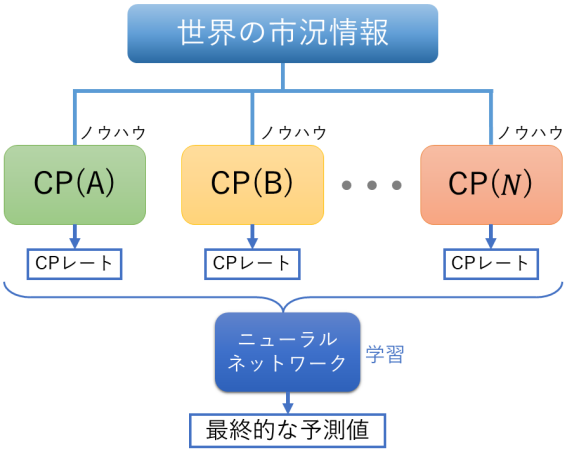

図 2: CP レートを用いたスタッキング (提案法)

3 問題設定

本研究では，2017 年 9 月 4 日から 9 月 30 日までの FX 業者に送信された計 12 社の CP レートから,「ドル円」,「ユーロ円」,「ユーロドル」の 3 つの通貨ペアを使用する．なお流動性が高く，マーケットインパクトが相対的に小さい (=市場参加者が多い) 当日午前 8 時から翌日午前 5 時までを 1 日分の市場データとして扱う．そして，ある 1 日を学習期間，次の 1 日をテスト期間とする．例えば,「9 月 4 日午前 8 時から 9 月 5 日午前 5 時のデータで学習→ 9 月 5 日午前 8 時から 9 月 6 日午前 5 時のデータでテスト」のように行った．外国為替取引は土日が休みのため，1 週間に行うシミュレーションは 4 期間となり，4 週間分のデータを用いたため合計 16 期間となる．また，送信されるレートは Bid(売値) と Ask(買値) の 2 値が存在するため，16 期間 × 2 値 = 計 32 パターンのシミュレーションを実施する． 予測対象の目的変数は時刻 $t+1$ (100[ms] 後) のドル円のベストレート (全 CP における最も高い Bid(売値) および最も低い Ask(買値)) とする．ドル円は通貨ペアの中でも流動性が高く，取引回数も多い利点がある．予測に用いる説明変数は，過去のドル円レートおよび関連するユーロ円およびユーロドルの 3 種類を用い，時間履歴を学習するように時刻を t (現在時刻)，$t-1$ (100[ms] 過去)，$t-2$ (200[ms] 過去) のようにラグを取ってニューラルネットワークに入力した．また，各通貨ペアにおいて為替レート $x(t)$ の価格帯が異なるため，収益率 $r(t)$ に変換した．

$$r(t) = \frac{x(t) - x(t-1)}{x(t-1)} \quad (2)$$

例として図 3 に，変換前と変換後の例を示す．ニューラルネットワークの構成として，出力層のニューロン数は 1 つであり，中間層のニューロン数は入力層の 1.1 倍 (バイアス項含む) に設定した．入力層のニューロン

数については，

- 個別法の場合：
  CP 数 $(=1)\times$ 通貨ペア数 $(=3)$
  $\times$ 時間履歴数 $(=3)+$ バイアス項 $(=1)=10$ 個

- 提案法の場合：
  CP 数 $(=12)\times$ 通貨ペア数 $(=3)$
  $\times$ 時間履歴数 $(=3)+$ バイアス項 $(=1)=109$ 個

となる．なお学習係数は全て 0.001 に設定した．

4 予測シミュレーション

4.1 正答率と F 値による評価

ニューラルネットワークの出力値である収益率 $\hat{r}(t+1)$ が正ならば次時刻の為替レート $\hat{x}(t+1)$ は上昇，負ならば下落，0 ならば不変とし，レート変動方向に関する正答率 A を評価する．しかし予測値 $\hat{r}(t+1)$ が丁度 0 になることは無いため，学習対象の目的変数について標準偏差 σ を求め，この $\pm\sigma$ の範囲内の $\hat{r}(t+1)$ を不変とみなした．正答率 A の算出には，

- 上昇と予測し，実際に上昇した回数：U_{win}
- 上昇と予測したが，反して下落した回数：U_{lose}
- 下落と予測し，実際に下落した回数：D_{win}
- 下落と予測したが，反して上昇した回数：D_{lose}

を用い，次式によって計算する．

$$A = \frac{U_{win} + D_{win}}{U_{win} + U_{lose} + D_{win} + D_{lose}} \tag{3}$$

このように不変と予測した場合を除くことで，元々のデータに不変の割合が多く正答率が 100[%] に近くなることを防ぐ．さらに，上昇または下落に関する二択問題となるため，50[%] を基準に有用性を評価できる．さらに，正答率を算出する際にデータ数の偏りを考慮して，F 値 (F–measure) による評価も行う．これは以下の適合率 $Precision$ と再現率 $Recall$ から算出される．

- Bid(売値) レートを予測対象にする場合

$$Precision = \frac{U_{win}}{U_{win} + U_{lose}} \tag{4}$$

$$Recall = \frac{U_{win}}{U_{win} + D_{lose}} \tag{5}$$

- Ask(買値) レートを予測対象にする場合

$$Precision = \frac{D_{win}}{D_{win} + D_{lose}} \tag{6}$$

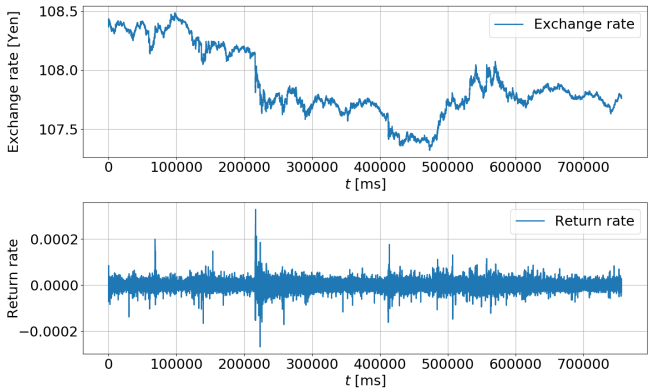

図 3: (上図) 実際の為替レート $x(t)$，(下図) 変換後の収益率 $r(t)$

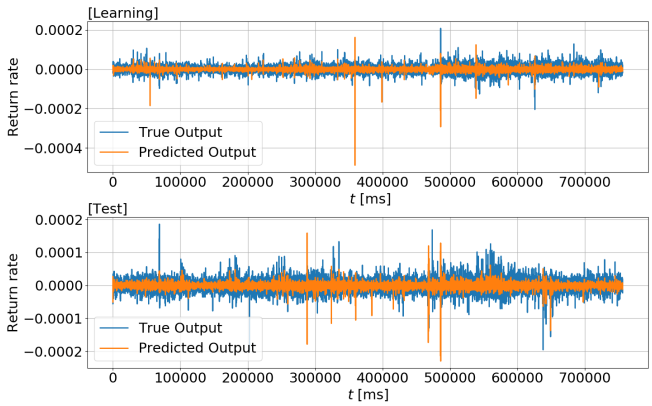

図 4: (上図) 学習時 (Learning) の真値 $r(t)$ と予測値 $\hat{r}(t)$，(下図) テスト時 (Test) の真値 $r(t)$ と予測値 $\hat{r}(t)$

$$Recall = \frac{D_{win}}{D_{win} + U_{lose}} \tag{7}$$

これらの F 値は以下のように算出される．

$$F = \frac{2Precision \times Recall}{Precision + Recall} \tag{8}$$

4.2 結果および考察

図 4 はある学習期間・テスト期間の収益率 (Return rate) の真値と予測値を示している．True Output は真値，Predicted Output は予測値である．このような結果に基づいて，提案法と個別法を比較した正答率の結果を表 1，F 値の結果を表 2 に示す．例として「9 月 5 日」が示すのは，9 月 5 日午前 8 時から 9 月 6 日午前 5 時である．各表において，個別法による結果を「CP(A),CP(B),⋯,CP(L)」の各項目に示す．また，個

別法による結果の平均値を $Mean\{\mathrm{CP}\}$と表す．表中の各項目において，Bid(売値) と Ask(買値) をそれぞれ予測した結果を同時に示している．これらより，提案法は必ずしも常に 1 位ではないが，安定して上位を保っている．対して個別法は良くなる場合も悪くなる場合もあり，順位が安定しない．この結果から，集合知の効果が発揮されていると考えられる．また，9 月 15 日のように提案法の値が著しく低い場合も確認できる．これは学習期とテスト期で相場が大きく異なり，学習した市場の動きがテスト期に適用していないためと考えられる．(2017 年 9 月 15 日は北朝鮮が弾道ミサイルを発射し，北海道上空を通過した後太平洋上に落下し，飛行距離が過去最長の約 3700km に達したとされたニュースがあり，これが為替変動に影響を及ぼした可能性がある．) また F 値において個別法の結果に大きな差が確認できるため，$+\sigma$ を上回り上昇と判別されたデータ数と，$-\sigma$ を下回り下落と判別されたデータ数に偏りがあると考えられる．

さらに図 5 および図 6 に示すように，正答率と F 値について，提案法と個別法 (平均値) の比較を行った．図 5 は正答率，図 6 は F 値を示す．それぞれ Bid(売値) と Ask(買値) の予測結果を示している．これらより，正答率は「9/14 の Ask」と「9/15」の 2 期間を除く全ての期間，F 値は全ての期間において，提案法が個別法 (平均値) を上回る結果となった．これらは各 CP によって異なる将来価格の見通しを集団学習によって統合することで，より先見力のある集合知を獲得できたことを示しており，この結果からも集合知の効果が発揮されていると考えられる．また，もし市場がランダムウォークならば正答率は上昇か下落の二択問題により 50[%] になると考えられるが，提案法ではほぼ全ての期間で 70[%] から 80[%] を超える値を示しており，個別法 (平均値) においてもほとんどの期間で 50[%] を超えている．したがって各 CP は市場を予測するノウハウを持っており，さらにスタッキングによってより優れた集合知を獲得できたと考えられる．

5 まとめ

本研究では，外国為替取引を仲介する FX 業者の立場になり，各 CP から配信される建値を各予測器からの出力値とみなし，これらをスタッキングによって集団学習する価格予測モデルを提案した．実際の建値データを用いた予測シミュレーションを通じて，個別の CP 毎で予測モデルを構築するよりもスタッキングによって全 CP を統合することで予測精度を向上できることを確認した．

6 今後の課題

自発的な収益獲得のため，本提案手法による価格予測を自己売買の判断材料に利用できる可能性がある．これについて投資シミュレーションを通じて検討する．また本稿においては 100[ms] 先を予測対象としているが，今後は 200[ms] 先や 300[ms] 先のように予測期間を延長しつつ，予測力を保持できるか検証する．

本研究の一部は，文科省科研費基盤研究 (C)(No.16K00320) の助成により行われました．

参考文献

[1] 本研究は某店頭外国為替証拠金取引取扱業者との共同研究である．

[2] 某店頭外国為替証拠金取引取扱業者から入手した．

[3] Trevor Hastie, Robert Tibshirani and Jerome Friedman, The Elements of Statistical Learning, Springer, 2008.

[4] Scott E. Page, The Difference: How the Power of Diversity Creates Better Groups, Firms, Schools, and Societies, Princeton University Press, 2008.

[5] James Surowiecki, The Wisdom of Crowds, Anchor, 2005.

[6] Tomoya Suzuki and Yuushi Ohkura, “Financial Technical Indicator Based on Chaotic Bagging Predictors for Adaptive Stock Selection in Japanese and American Markets,” Physica A, vol.442, pp.50–66, 2016.

[7] Tomoya Suzuki, “Consensus Ratio and Two-steps Selection to Detect Profitable Stocks,” International Federation of Technical Analysts (IFTA) Journal, vol.18, pp.4–14, 2018.

[8] Eugene F. Fama, “Efficient Capital Markets: A Review of Theory and Empirical Work,” Journal of Finance, vol.25, no.2, pp.383–417, 1970.

[9] Zhi-Hua Zhou, Ensemble Methods Foundations and Algorithms, Taylor & Francis Group, 2012.

[10] 西垣通，集合知とは何か，中公新書，2013.

[11] Tomoya Onizawa, Takehiro Suzuki, Tomoya Suzuki, “Predictability of Financial Market Indexes by Deep Neural Network,” Proceedings of 2017 International Symposium on Nonlinear Theory and its Applications, pp.166–169, 2017.

表 1: 各テスト期間における正答率 [%]：Bid(左)/Ask(右)．各列において正答率が高い 3 位までを太字で示す．

テスト期間	9 月 5 日	9 月 6 日	9 月 7 日	9 月 8 日	9 月 12 日	9 月 13 日	9 月 14 日	9 月 15 日
CP(A)	**77.77**/55.00	59.24/62.27	67.31/65.06	66.23/67.39	68.80/62.70	67.31/**72.73**	61.68/50.79	**73.38**/**74.41**
CP(B)	**78.83**/63.84	72.91/70.32	61.46/51.37	64.93/74.03	44.35/62.45	**71.67**/68.55	0.00/0.00	0.00/0.00
CP(C)	36.70/49.28	68.19/51.34	62.48/64.25	68.50/63.80	56.55/51.71	**70.88**/56.79	59.17/44.48	70.38/49.59
CP(D)	65.85/35.47	63.07/68.42	**72.86**/70.60	**72.83**/66.26	**74.38**/72.85	68.58/71.29	**69.46**/**75.07**	62.47/50.60
CP(E)	76.51/**71.00**	69.34/**72.14**	61.36/**72.16**	68.93/**74.53**	**74.21**/**78.77**	63.75/70.93	62.44/37.32	**79.54**/61.03
CP(F)	71.43/33.33	61.89/71.44	66.28/54.39	59.04/73.76	55.11/66.75	46.81/72.36	57.96/56.70	71.53/50.75
CP(G)	74.98/65.90	**75.98**/**77.03**	68.23/67.88	71.32/**79.89**	74.09/72.78	41.88/**75.81**	65.60/68.56	71.94/68.39
CP(H)	60.71/64.67	68.94/69.99	69.13/60.10	69.77/58.95	66.48/65.83	59.18/59.42	60.37/51.05	**75.74**/65.37
CP(I)	56.41/62.82	52.06/57.54	56.08/55.32	54.17/57.14	53.41/66.91	64.47/51.92	61.88/53.87	63.55/**72.33**
CP(J)	68.63/**69.29**	75.48/70.38	68.96/62.52	52.28/73.60	67.16/**74.89**	68.97/56.94	**68.98**/**70.21**	70.94/63.66
CP(K)	29.82/53.93	**75.90**/70.05	**74.98**/65.50	**80.15**/65.65	72.98/67.92	67.98/71.29	**66.37**/**69.70**	69.53/**84.29**
CP(L)	57.14/48.24	63.36/67.55	56.06/**71.14**	70.71/60.52	62.68/61.21	48.11/65.48	47.14/44.21	68.45/59.80
$Mean\{$CP$\}$	62.90/56.06	67.20/67.37	65.43/63.36	66.57/67.96	64.18/67.06	61.63/66.13	56.75/51.83	64.79/58.35
提案法	**80.91**/**77.78**	**78.67**/**77.29**	**76.96**/**75.80**	**79.24**/**80.40**	**76.09**/**78.03**	**75.85**/**77.68**	64.29/49.13	48.00/56.67

テスト期間	9 月 19 日	9 月 20 日	9 月 21 日	9 月 22 日	9 月 26 日	9 月 27 日	9 月 28 日	9 月 29 日
CP(A)	69.86/71.41	60.34/58.35	70.32/66.02	70.24/**77.45**	72.50/70.61	71.84/57.80	62.67/70.97	71.86/59.94
CP(B)	66.68/68.34	**68.03**/**69.32**	**75.03**/71.86	78.95/69.24	66.14/67.20	72.85/68.83	68.99/68.04	72.72/71.87
CP(C)	63.02/47.49	52.53/62.97	65.25/57.79	59.32/66.67	44.03/49.27	65.16/62.30	57.11/53.14	51.79/57.34
CP(D)	55.82/71.67	57.96/68.48	45.45/76.82	**81.97**/69.77	67.34/56.02	**73.50**/**75.05**	71.34/**73.60**	**80.00**/**79.45**
CP(E)	**72.07**/63.38	42.42/**69.80**	51.35/60.00	**81.66**/72.14	**75.11**/69.85	**80.17**/69.49	**79.63**/**77.30**	74.03/**78.62**
CP(F)	62.36/**77.11**	58.35/65.39	67.98/70.62	56.93/74.70	67.38/73.05	56.71/69.17	66.86/67.94	64.54/71.94
CP(G)	71.76/68.49	**67.25**/69.00	63.30/**78.52**	**80.68**/74.34	68.22/**77.35**	67.47/71.73	67.31/70.33	**80.05**/75.74
CP(H)	**73.63**/68.08	63.26/56.50	75.00/66.42	46.00/58.82	67.20/66.27	71.56/66.89	51.59/71.33	56.34/71.43
CP(I)	63.13/48.35	62.54/51.41	67.98/68.23	56.25/72.55	72.45/59.93	68.31/64.93	66.66/72.63	54.58/59.06
CP(J)	70.16/70.91	62.61/46.66	65.88/**83.36**	77.52/**77.76**	69.20/65.01	58.23/72.01	66.57/70.21	71.06/65.70
CP(K)	68.56/**76.08**	66.68/68.21	67.12/54.31	76.60/70.94	**73.98**/72.25	44.30/**78.25**	68.77/72.04	71.55/69.03
CP(L)	71.70/52.87	49.16/44.58	**77.98**/74.61	78.60/67.53	68.19/**73.92**	70.94/70.51	**72.78**/58.57	64.52/66.34
$Mean\{$CP$\}$	67.40/65.35	59.26/60.89	66.05/69.05	70.39/70.99	67.65/66.73	66.75/68.91	66.69/68.84	67.75/68.87
提案法	**73.53**/**75.87**	**71.87**/**71.55**	**76.75**/**84.62**	77.22/**78.86**	**78.55**/**80.36**	**77.93**/**78.55**	**79.49**/**78.85**	**79.71**/**80.09**

表 2: 各テスト期間における F 値 [%]：Bid(左)/Ask(右)．各列において F 値が高い 3 位までを太字で示す．

テスト期間	9 月 5 日	9 月 6 日	9 月 7 日	9 月 8 日	9 月 12 日	9 月 13 日	9 月 14 日	9 月 15 日
CP(A)	6.07/45.45	73.82/63.18	64.43/63.72	59.14/74.22	69.13/60.02	67.10/71.31	63.44/51.69	**74.65**/**85.14**
CP(B)	0.44/67.24	71.95/**73.77**	57.32/31.18	65.58/1.19	61.45/66.63	68.10/72.40	0.00/0.00	0.00/0.00
CP(C)	31.21/65.79	70.33/48.77	68.21/**76.89**	17.57/69.05	34.18/40.93	41.81/40.26	**69.97**/2.00	30.99/61.13
CP(D)	51.59/16.59	4.96/**75.86**	**70.92**/74.78	**83.96**/78.49	62.83/75.89	**68.23**/73.09	63.81/0.85	68.59/63.72
CP(E)	**85.67**/**69.69**	70.46/70.91	64.26/**75.42**	**81.06**/**84.36**	**74.67**/**77.81**	11.60/**78.91**	56.20/25.07	**77.31**/5.12
CP(F)	**83.33**/40.00	47.47/36.52	63.00/56.22	9.41/72.22	68.27/59.87	40.97/69.09	**71.23**/25.46	70.81/28.22
CP(G)	60.24/0.28	**75.70**/73.73	28.93/**79.15**	19.72/**84.45**	71.40/74.98	43.54/13.24	62.48/45.62	**77.21**/5.51
CP(H)	72.35/65.39	23.80/66.84	69.36/57.11	78.64/31.32	59.79/44.40	6.08/44.42	63.29/63.30	60.20/**79.03**
CP(I)	4.57/**69.33**	38.71/65.79	57.19/27.62	67.81/71.26	18.52/29.64	29.34/35.01	65.46/**64.27**	43.07/24.80
CP(J)	79.26/61.11	75.01/68.15	69.70/12.42	46.51/**84.38**	68.56/**78.62**	**68.34**/8.24	7.59/15.13	74.39/76.01
CP(K)	25.93/29.88	**77.03**/68.65	**74.98**/63.20	**84.96**/71.41	**74.81**/72.64	55.37/67.36	50.04/**77.70**	73.33/**87.36**
CP(L)	66.67/60.71	52.65/69.25	62.98/71.65	72.78/37.62	54.39/47.05	45.97/**74.79**	39.19/47.25	52.58/46.67
$Mean\{$CP$\}$	47.28/49.29	56.82/65.12	62.61/57.45	57.26/63.33	59.83/60.71	45.54/54.01	51.06/34.86	58.59/46.89
提案法	**79.73**/**78.00**	**77.91**/**76.89**	**76.25**/74.76	78.07/80.07	**75.76**/**76.81**	**75.29**/**76.72**	**73.68**/**65.89**	62.86/72.34

テスト期間	9 月 19 日	9 月 20 日	9 月 21 日	9 月 22 日	9 月 26 日	9 月 27 日	9 月 28 日	9 月 29 日
CP(A)	**73.26**/72.68	56.50/32.47	**81.77**/48.96	5.26/77.17	73.74/**81.78**	35.10/54.79	76.77/68.57	72.71/68.26
CP(B)	65.78/65.47	63.01/**68.81**	41.38/1.29	74.10/68.71	15.66/60.96	11.96/61.49	**81.25**/62.42	53.71/73.77
CP(C)	37.18/52.17	31.17/68.78	0.18/10.87	66.76/**78.79**	34.91/57.46	76.20/62.81	26.56/48.11	28.85/12.37
CP(D)	57.32/65.09	65.92/67.01	45.45/14.63	55.17/45.83	69.72/32.26	**77.48**/**75.48**	67.08/5.00	**80.20**/72.64
CP(E)	**79.17**/**77.44**	45.01/56.18	10.00/60.00	60.08/**80.14**	**74.90**/70.10	**86.15**/66.98	**79.87**/**72.87**	**81.98**/**77.36**
CP(F)	47.83/75.78	44.78/59.56	66.94/0.35	71.46/**82.82**	22.93/67.69	30.95/66.98	16.78/43.58	47.83/59.40
CP(G)	69.95/66.51	**72.35**/**81.28**	7.59/**76.37**	50.61/71.68	**74.90**/77.14	68.81/46.25	64.57/54.63	50.33/48.59
CP(H)	57.95/**79.71**	**75.10**/59.54	**76.16**/**65.30**	52.63/60.51	24.98/44.77	64.73/68.62	55.77/**68.96**	9.10/19.94
CP(I)	31.05/59.76	**73.92**/55.74	**80.83**/0.90	48.15/28.61	56.65/72.51	70.36/56.40	60.65/19.83	68.67/69.51
CP(J)	66.03/16.36	54.43/35.07	69.91/40.50	**77.57**/71.97	69.58/**77.67**	18.54/65.35	71.31/19.44	73.27/76.27
CP(K)	14.11/**80.43**	57.32/12.42	25.00/60.74	**74.32**/48.49	74.29/71.71	55.78/47.74	4.32/61.29	47.38/**78.15**
CP(L)	**82.88**/62.36	42.46/34.52	1.00/58.00	1.86/64.08	71.41/25.75	48.29/**69.66**	8.70/27.18	36.64/68.35
$Mean\{$CP$\}$	56.88/64.48	56.83/52.62	42.18/36.49	53.16/64.90	55.31/61.65	53.70/61.88	51.14/45.99	54.22/60.38
提案法	72.66/75.34	71.27/**70.74**	71.87/**84.03**	**76.90**/77.87	**77.86**/**79.58**	**77.66**/**78.01**	**79.16**/**77.83**	**78.30**/**79.00**

※「0.00」は予測値が全て $\pm\sigma$ の範囲内となり，不変と判別されたためである．

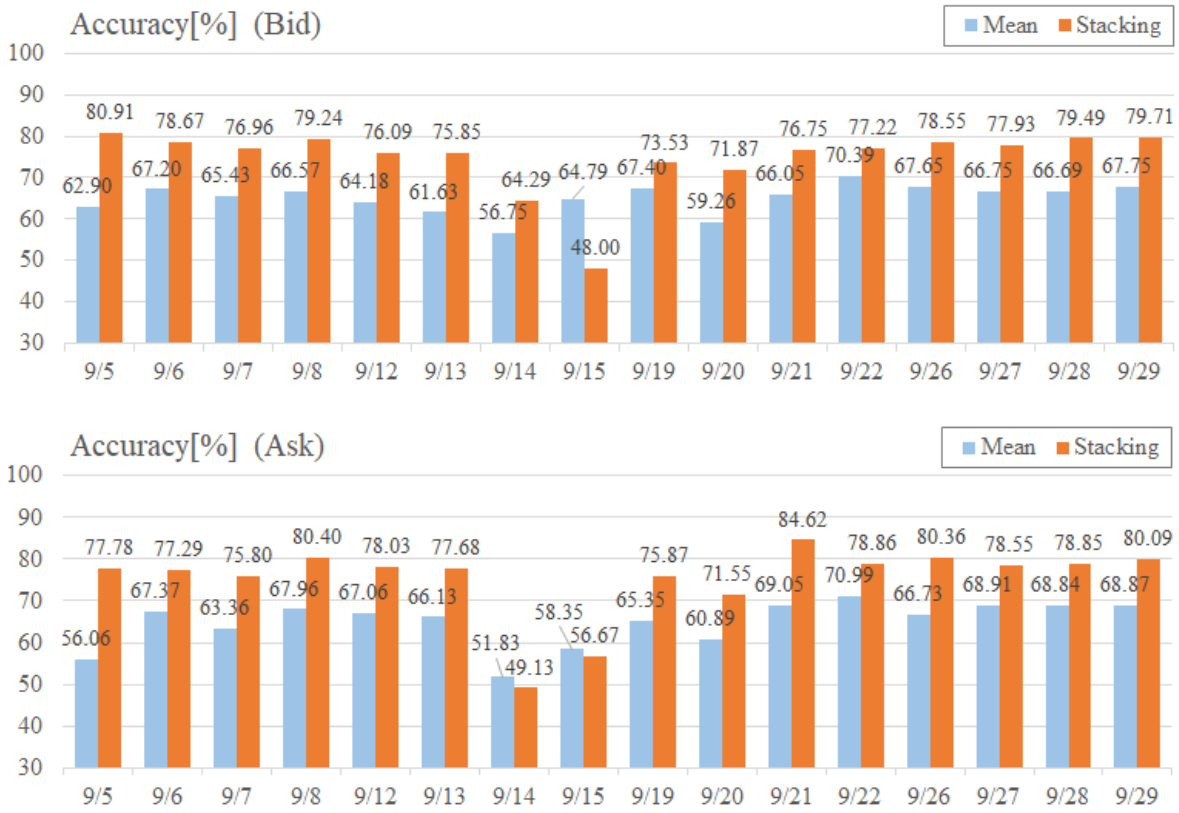

図 5: Mean(個別法 (平均値)) および Stacking(提案法) による Accuracy(正答率) の比較

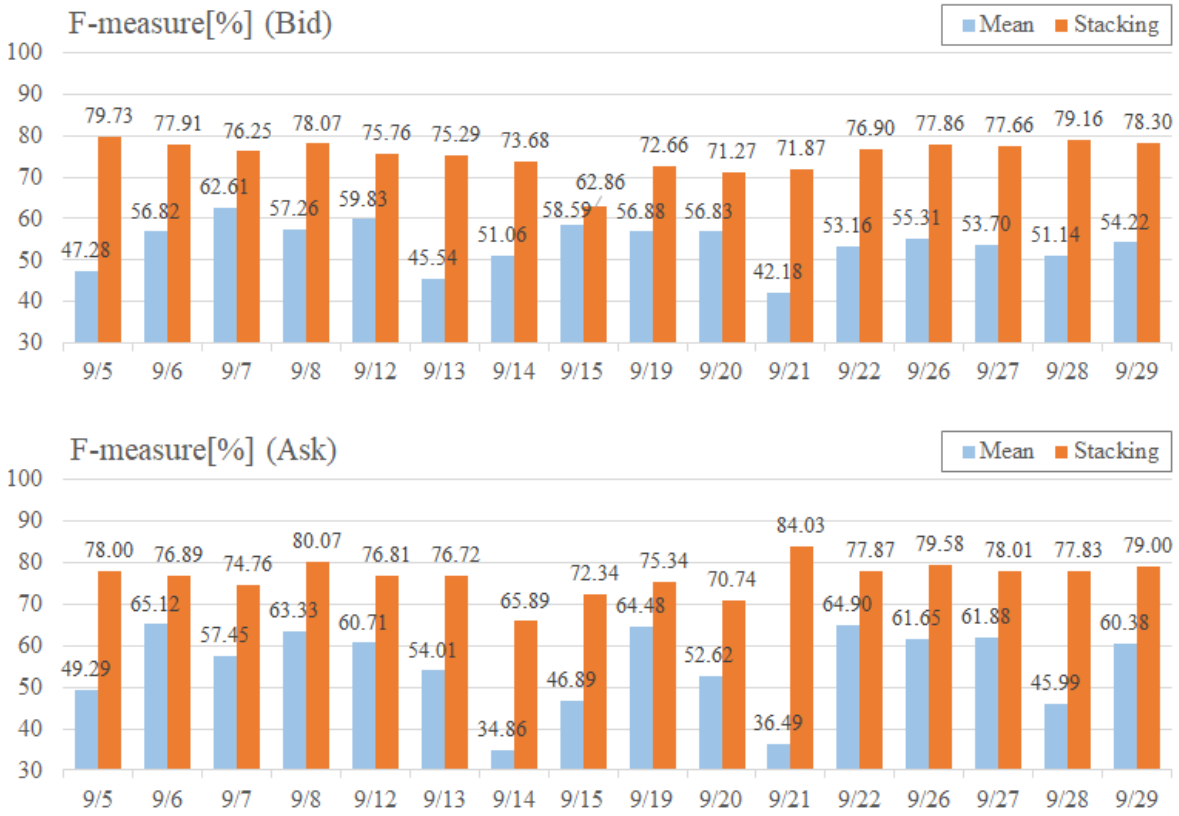

図 6: Mean(個別法 (平均値)) および Stacking(提案法) による F–measure(F 値) の比較

事業部間シナジー効果の測定と M&A における関連性

Measurement of Synergy Effect between business and Relevance in M&A

松本　裕介 [1]　菅　愛子 [1]　高橋　大志 [1]

Yusuke Matsumoto[1], Aiko Suge[1], and Hiroshi Takahashi[1]

[1] 慶應義塾大学大学院経営管理研究科
[1]Graduate School of Business Administration, Keio University

Abstract: As business environment changes rapidly, companies must respond to the change. As one of countermeasures against big change, divestment by M&A is becoming one of the options. In this paper, we classify the industries by using FCM in order to reflect the trend in industrial classification that business structure changes drastically, we analyze what kind of companies divest business. As a result of analyzing during 15 years from 2002 to 2016, we found that companies with higher debt ratio would divest the business. Analyzing the effectiveness of industrial classification by fuzzy c means is one of our future works.

1.はじめに

変化が激しい現代では、企業は事業環境の変化に合わせて、柔軟に事業再編を実行することが求められている。企業が事業環境に合わせる手段の一つとして M&A が挙げられる。従来、日本企業は M&A を通して、事業を売却することには慎重であった。しかし変化が激しい現代において、企業の持続的成長を支えるための事業売却の恩恵を日本企業の経営陣も認識し始めており、従来の考えが変化しつつある。こうした背景から、日本企業がコアでない資産や不採算事業を整理、既存の事業を合理化するために、事業売却は執るべき、考えるべき選択肢の一つになり始めている。

本論文の構成は以下の通りである。まず第 2 章では、本論文のテーマと関連する研究につて述べる。第 3 章で分析に使用するデータについて説明する。第 4 章では分類と信頼性の比較を行う。そして最後に、第 5 章で本論文のまとめと課題について述べる。

2.先行研究

企業の一部を譲渡する方法として事業譲渡(売却)と会社分割がある。事業譲渡や会社分割には、スピンオフ [1]、カーブアウト [2]など多様な手段が存在しており、各手法に対して数多くの業績改善効果の検証が行われている。事業売却を行うことで、利益や企業価値が上昇する理由として、事業の集中度の増加、他事業の悪影響の消去、事業の多角化効果が主な理由として挙げられる。事業の集中度が増す事に関する研究として、Denis and Shome [2] がある。Denis and Shome [2] によると、資産削減を行った企業はより本業に集中し、結果として生産性が向上すると述べている。他事業の悪影響の消去に関する研究として、Dittmer and Shivdasani [3] がある。Dittmer and Shivdasani [3] によると、事業売却はコングロマリット・ディスカウントを減少させるとし、さらに売却後、残った事業に対して投資を行った場合、その改善効果はさらに大きくなると述べている。事業の多角化効果に関する研究として、Berger and Ofek [4] がある。Berger and Ofek [4] では、多角化は企業価値を減少させると述べ、税の控除や負債比率の増加の形で適切に多角化を進めることで利益につながると報告している。

3.データ

本論文では、東証一部上場企業を対象に、2002 年度から 2016 年度までの財務データを用いて分析を行った。分析対象企業数は 1210 社である。データは日経 NEEDS より入手した。なお本論文では、日経業種分類において金融・証券・保険の各業種に属す

[1] スピンオフとは、会社分割の一種で、親会社の資産と業務の一部を切り出して設立された新しい独立した企業のことである。新会社の株式は元の会社の株主に交付される[1]。

[2] カーブアウトとは、会社分割の一種で、親会社が戦略的に子会社や自社の事業の一部を切り出し、新会社として独立させることを意味する。スピンアウトとは、新会社の株式が既存の株主に分配されるのではなく、公募により売却されるという点で異なる[1]。

る企業や、総務省分類・大分類において複合サービス事業や公務、分類不能の産業に属する企業、分析において必要となるデータが入手できない企業を除外している。

M&A に関連する情報については、レコフ M&A データベースから収集した。レコフが提供する M&A データには M&A データやグループ内 M&A データ、分社・分割データ、子会社株式取得データ等を含む M&A 関連データが含まれている。本論文では M&A によって事業売却を行う企業の特徴を探るため、M&A データのみを使用する。

Fuzzy C means によって新たな業種分類を構築する際、また実証分析を行う際に用いる変数は以下の表 1 の通りである。

表 1: 記述統計量

変数名	平均	中央値	最小値	最大値	企業数	サンプル数
営業利益率	0.059	0.048	-3.319	0.689	1210	18150
自己資本比率	0.487	0.482	-0.473	0.973	1210	18150
総資産回転率	1.059	0.935	0.003	6.310	1210	18150
売上高成長率	0.035	0.025	-0.895	10.484	1210	18150
シナジー効果/企業価値	-0.094	-0.068	-1.987	0.756	251	3765
EBITDA/売上高	0.091	0.085	-0.134	0.426	251	3765
負債比率	0.492	0.497	0.043	1.145	251	3765
$EBITDA_{(-1)}$/売上高$_{(-1)}$	0.094	0.087	-0.098	0.458	251	3765
負債比率$_{(-1)}$	0.497	0.503	0.039	1.289	251	3765

4.分析手法

4.1 シナジー効果

本章では、本論文で使用するシナジー効果の計測方法について説明する。本研究では、Berger and Ofek [4]と中野・野間[5]を参考にし、シナジー効果を算出した。

本論文では、企業が持つセグメントの価値の総和(理論価値)と企業価値の差をシナジーと定義する。差が正の場合はプラスのシナジー効果があると呼び、差が負の場合はマイナスのシナジー効果があると呼ぶことにする。

本論文では、セグメントを複数有している企業を多角化企業、1 つだけ有している企業を専業企業と定義する。多角化企業の場合に限って、企業価値は、企業が持つセグメントの価値の総和と、セグメントの組み合わせによるシナジー効果による価値に分けることができる。図 1 に全体のイメージ図を示す。

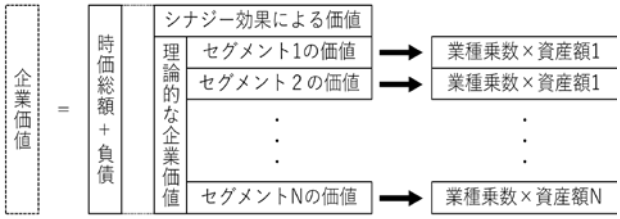

図 1: 全体のイメージ図

多角化企業iの企業価値は、時価総額と負債簿価で計算する。

$$\text{企業価値} = \sum \text{セグメントの価値} + \text{シナジー効果}$$

多角化企業iのセグメントjの理論価値は、セグメントjの資産額とそのセグメントjが属する業種の平均的な乗数$IndM_{ij}$の積で表せる。

セグメントijの価値

$$= \text{セグメント}j\text{の業種乗数}\ (IndM_{ij})$$

$$\times \text{セグメント}j\text{の資産額}$$

セグメントjが属する業種の平均的な乗数$IndM_{ij}$は専業企業を用いて以下のように算出する。

$$\text{セグメント}j\text{の業種乗数}\ (IndM_{ij})$$

$$= median\left(\frac{\text{専業企業}i\text{の企業価値}}{\text{専業企業}i\text{の資産}}\right)$$

上記のように、同じ業種に属する専業企業から複製して計算した理論価値と、時価総額と負債総額から計算される企業価値の差を計算することでシナジー効果を算出する。

4.2 業種分類

シナジー効果を算出する際、各企業が専業企業なのか多角化企業なのか、また各企業が何処の業種に属しているかを知る必要がある。従来、日経業種分類や東証業種分類などの業種分類では、一企業に対して 1 つの産業分類コードだけを割り振っており、多角化企業か否かを客観的に判断できない。また日経 NEEDS は 1 つのセグメントに、最大 3 つの産業分類コードを振っており、多角化企業か専業企業を客観的に判断することができる。しかし、多角化が進む企業の場合には 3 つより多くの産業分類コードを割り振る必要があるということ、企業の売上高を基準に業種分類を行っているということから、企業の状況を正しく反映できていない可能性がある。これらを考慮し、新たな業種分類を構築した。

本論文では、Matsumoto, Suge and Takahashi [6]を参考にして、財務指標を基に Fuzzy c means 法(FCM) [7]を用いて企業をグルーピングするとともに、各企業に対して業種の割り振りを行った。FCM の特徴は、ファジィ集合を導入することにより、学習ベクトルが 2 つ以上のクラスターに属することを可能にしていることである。FCM は以下のように表せる。

$$J = \sum_{i=1}^{N} \sum_{k=1}^{K} (g_{ik})^m \|x_i - c_k\|^2$$

上式に関して、目的関数Jをg_{ik}について最小化することで、帰属度g_{ik}を得ることができる。また目的関数Jをc_kに関して最小化することで、重心ベクトルc_kを得ることができる。

本論文では、初期のクラスター数Kを、今回使用している業種分類である総務省大分類と同じ 17 と設定した[3]。また距離$\|x_i - c_k\|$はユークリッド距離を採用し、ぼかし度合いmは 2 とした。データx_iの対象は、収益性を示す営業利益率、安全性を示す自己資本比率、活動性を示す総資産回転率、成長性を示す売上高成長率とした。なお分析の際、標準化を行った。

分析の結果として、各企業は 17 個のクラスターそれぞれに対して帰属度g_{ik}を持つ。それらの中で、帰属度g_{ik}が最も高いクラスターから、その企業の第 1 業種、第 2 業種と名前を付けた。なお本論文ではクラスターを業種と呼ぶことにする。

5.実証分析

本論文では、Schlingemann, Stulz and Walkling [8] を参考に、ロジットモデルを用いて、事業売却を行う企業の特徴を分析した。ロジットモデルに対する被説明変数は、各年に企業が M&A にて売却した場合に 1、売却しなかった場合に 0 とするダミー変数である。

分析手法に対する説明変数は、EBITDA/売上高と負債比率、シナジー効果/企業価値の 3 つである。EBITDA/売上高に関して、M&A で売却を行う企業は事業悪化に対する対応であることが多く、本業による利益を示す EBITDA/売上高が低い企業ほど M&A で売却する、と考え説明変数に選択した。負債比率に関して、負債比率による事業悪化に対応するため、M&A で売却をする、と考え説明変数に選択した。シナジー効果/企業価値に関して、シナジーが出ていない多角化企業ほど、M&A にてシナジーが出ていない事業を売却し、シナジー効果を出しやすくする、と考え説明変数に選択した。

EBITDA/売上高と負債比率、シナジー効果/企業価値は分母と分子のそれぞれに 1 期ラグを取っている。また EBITDA$_{(-1)}$/売上高$_{(-2)}$、負債比率$_{(-1)}$は、分子にラグを 1 期、分母にラグを 2 期とっている。これは、企業の意思決定は、単年度の業績に応じて決定されるものではなく、複数年度の状況を鑑みて意思決定をすると考えられるからである。

期間は 2002 年から 2016 年の 15 年間で分析を行った。

6.分析結果

実証分析の結果は以下の表 2 の通りである。2002 年から 2016 年までを対象とした場合、Hausman 検定や Log Likelihood ratio 検定から共に固定効果モデルが支持された。表 2 の結果を見ると、分母と分子でそれぞれラグ 1 期とった負債比率が、有意にプラスを示す結果となった。これは、負債比率が高い企業ほど M&A にて売却を行うと意味する。15 年間でみると、企業は直近の業績悪化に対応するために、M&A にて売却を行っているということわかる。これは、Schlingemann, Stulz and Walkling [8] が 1979 年から 1994 年の 15 年間で、本論文と同様の分析を行った際の結果と一致している。それゆえ、長期間で分析すると、企業が事業を売却しようと考える際の要因は過去からほとんど変わらないといえる。シナジー効果/企業価値に関して、2 つのモデルでは有意な結果となっていない。しかし、シナジー効果/企業価値の係数がともに負である。ゆえに今後、シナジー効果を意識する企業はどういう企業なのかを企業規模や時代の変遷を考慮して分析していく予定である。

[3] FCM では、初期値としてクラスター数Kを事前に設定しなければならない。本論文では、クラスター数を決めることを目的としていない。ゆえに初期値として与えるクラスター数を、日本標準産業分類にて本論文で対象とする企業が所属している業種数である 17 種類として一度設定した。

表 2: 実証分析結果

被説明変数＝M&Aかつ売却したか否か
期間=2002-2016

	固定効果 ロジット	固定効果 ロジット
EBITDA/売上高	2.109	
負債比率	2.717***	
シナジー効果/企業価値	−0.372	
$EBITDA_{(-1)}$/売上高$_{(-2)}$		−0.008
負債比率$_{(-1)}$		1.107
シナジー効果/企業価値		−0.324
サンプルサイズ	3765	
被説明変数：0	3498	
被説明変数：1	267	

(注１)ハウスマン検定と Log likelihood Ratio 検定より、固定効果モデルが支持された。
(注２)値は偏回帰係数を示す。
(注３)***は 1%水準で有意、**は 5%水準で有意、*は 10%水準で有意であることを示す。

7.まとめ

本論文では、新たな業種分類の方法を通してシナジー効果を測定することに加えて、事業環境の変化に合わせて事業売却を行う企業の特徴を分析した。分析結果から、直近の業績にて負債の比率が大きくなった企業ほど、M&A で売却を行うということが分かった。

最後に、本論文における課題を 2 点示しておきたい。第 1 に、新たな業種分類の方法が効果的なのかを詳細に検証することである。本論文の結果から、シナジー効果に関しては、有意な結果を得ることができなかった。ゆえに、FCM による分類に関する問題であるのか、または分析期間が長期であることによって、結果が見えづらくなっているのかなど様々な可能性が考えられる。今後、これらの詳細な分析を通して、その有効性を確認する必要がある。第 2 に、様々な要因を考慮して、より詳細に分析を行うことである。ロジットモデルにおける分析を行う際に、説明変数として負債比率の他に、EBITDA/売上高とシナジー効果/企業価値を用いた。後者２つの変数は、M&A による事業売却の際に考慮していると考えられるが、本論文での分析において、有意な結果を得ることができなかった。今後、そのような現象が生じた理由を、企業規模や分析期間など様々な要因を考慮して詳細に分析する必要がある。

参考文献

[１] リチャード・A, スチュワート・C, フランクリン・A: コーポレートファイナンス, 日経 BP 社, 第 10 版 (2014)
[２] Diane K., Dilip K.: An empirical investigation of corporate asset downsizing, Journal of Corporate Finance 11.3 (2005)
[３] Dittmar, A., Shivdasani, A., Divestitures and divisional investment policies, The Journal of Finance 58.6 (2003)
[４] Philip G., Eli Ofek., Diversification's effect on firm value, Journal of financial economics 37.1 (1995)
[５] 中野誠, 野間幹晴: 日本企業のバリュエーション—資本市場における経営行動分析—, 中央経済社, 第 1 版第 1 刷, (2009)
[６] Matsumoto Y., Suge A., Takahashi H.: Construction of new industrial classification through fuzzy clustering, Working paper (2018)
[７] Bezdek, C., Robert E., William F.: FCM: The fuzzy c-means clustering algorithm, Computers & Geosciences 10.2-3 (1984)
[８] Moeller, S., Schlingemann, P., Stulz M.: Firm size and the gains from acquisitions, Journal of financial economics 73.2 (2004)

ビジネスゲームによる企業不祥事に対する忖度の影響に関する研究

システム情報工学研究科
リスク工学専攻
脊板弘康

概要

顧客第一主義を標榜し、品質第一主義を掲げて世界を席巻してきた日本企業で今、品質詐称事件が後を絶たない。企業組織が当初から悪意を持って詐称に及んだ事例もあるが、赤福事件の様に一見善意から詐称事件へと発展した例もあり、そこには日本独特の高コンテクスト社会が生んだ「忖度」の存在がみられる。

本研究では Giddens の構造化の理論の枠組みを基に、日本独特の精神文化とも呼べる「忖度」が意図せざる不祥事へと企業組織を導いて行く様を、ビジネスゲームと表情分析を用いて再現させ、そのメカニズムを解明することを目的としている。また、このような方法が従来のアンケートで難しいと思われる動的な組織変容過程の研究に有効であることを示し、その構想を報告する。

1. 研究の背景

1.1.本研究の目的

本研究では日本のメーカーにおいて組織的な詐称の発生過程において日本独特の文化としての「忖度」の影響を、ビジネスゲームを用いて再現し明らかにする事を目的とする。

1.2.日本企業の品質第一主義の組織文化と企業不祥事

生産活動においてＺＤ運動はＱＣ活動とともに日本の品質管理において主要な行動規範の一つになっており近年においも日本の物造り産業において生産活動だけではなくサービス産業においても重要視され多大な貢献があるといわれている。一方で、不良ゼロの合言葉は品質偏重による管理コスト増大、ひいては高コスト体質の原因になっているとの指摘も有る。脊板（2018）が行った研究では生産の第一線において品質や生産コスト決定の中心的役割を担う工程エンジニアの不良発生時の問題解決行動を分析することにより、コストが重要視されている生産現場においても品質がコストに比較して圧倒的に重視されていることを明らかにした。結論では明らかに、

品質　＞＞　コスト

で日本企業では明らかに品質を第一に重視していることが示された。

しかし、近年においても神戸製鋼、東洋ゴム、タカタベルトなど日本を代表する製造メーカーに於いても、品質詐称事件が相次いで発生しているのはなぜであろうか。

2. 本研究テーマに関する既存研究

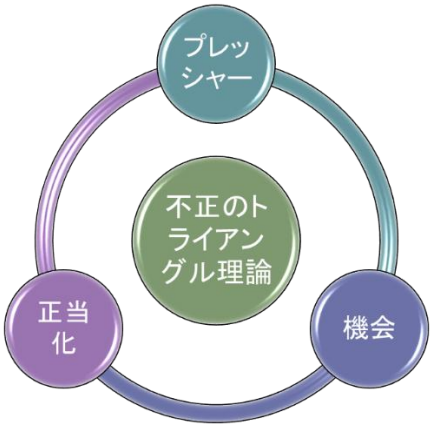

2.1. 詐称が起こるメカニズム

米国の組織犯罪研究者ドナルド・R・クレッシーは詐称が発生メカニズムを「不正のトライアングル理論」として次のように体系化した。(The　Fraud　Triangle)

① 「プレッシャー」（Ｐｒｅｓｓｕｒｅ）～例えば、納期や生産性に関する過大な欲求を満たさねばならないなど心理的圧力。

② 「機会」（Ｏｐｐｏｒｔｕｎｉｔｙ）～不正を行おうとすれば可能な環境が存在する状態。

③ 「正当化」（Ｒａｔｉｏｎａｌｉｚａｔｉｏｎ）～「従業員のコンプライアンスの意識の欠如」や会社の仕組みが脆弱で詐称を起こしても発覚しにくいといった環境や仕組みに由来するもの。

これらは、多くの詐称事例に共通して見られるものであるが、あくまでも定性的である。各要素がどの程度の大きさになれば実際の詐称に至るのか定量的にとらえることは具体的な原因検討や対策において重要であるが、その定量化については検討されていない。

定量化の方法の例としては、例えば大倉（2001）の保険金の不正請求に関して効用関数を用いたゲーム理論的アプローチがある。会社が被る不正請求額とそれに対する調査費用と不正を犯そうとする側の損失からどの程度保険会社が調査を行えば不正請求を抑制できるのかを論じたものである。

２.2.先行研究の問題点

大倉（2001）の保険金の不正請求に関して効用関数を用いたゲーム理論的アプローチでは、会社が被る不正請求額とそれに対する調査費用と不正を犯そうとする側の損失からどの程度保険会社が調査を行えば不正請求を抑制できるのかを検討している。

この試みは上述の「不正のトライアングル」の内、組織の仕組みに起因する「機会」のみを考慮したもので「プレッシャー」や「正当化」など組織文化に起因する要因を考慮したものではない。また、従来の研究においては日本固有の社会特性であるハイコンテクスト社会、協調性の高さに起因するいわゆる「忖度」についてそのメカニズムを定式化し定量的に検討された研究は少ない。

組織内においてどの程度リスクが高い状態なのかを調べる方法としてはアンケートなどが用いることが考えられるが、社内の問題を語る事に対する抵抗感や被験者が部外者である場合、十分な現実感を持って回答する事は難しいと思われる。

３． 企業不祥事に関する先行研究の課題

３.1. 従来の実証研究における課題

① 従来の研究では、事後にまとめた報告書から原因メカニズムを構築しているが、ある時点の議事録や断片的な証言をつなぎ合わせ発生メカニズムとしている為、事件に対する懲罰に対する恐れや会社関係者への配慮などのバイアスが考慮されていない。従って、原因に対する見方が平面的で当事者相互の心理的な葛藤や組織の権力の影響、そこから発生する組織風土や行動規範の変化といった要素が考慮されていない。

② 例えば良かれと思って行動した結果が、図らずも詐称となるケース（「赤福事件」や「雪印乳業食中毒事件」）においては、なぜ善意に基づく行動が組織を変容させ不祥事に至らしめたのかを説明できていない。

③ 現状のスキームでは、個人と組織、社会のダイナミックな相互作用を取り込めていない。

④ 組織の変容は時系列的な再帰性をともない発展するため悪化の度合いや原因を特定しにくい。従って、そこからの対策も本質的で効果のあるものではない可能性が高い。

そこでメカニズムに①人間の心理や認知行動②組織文化、③権力、④個人と組織、社会の相互作用を時系列変化として取り込める理論的な枠組みを探査すべく、これらを包括できる社会学、組織文化論に枠を広げてサーベイを行った。

３.2. 先行研究に見る実証研究の課題

➢ ジェームス・リーズン（1999)「組織事故」日科技連

組織不祥事は組織の持つ潜在的な危険性をカバーする深層防御（規則や手順書、訓練、管理業務、資格認定といったソフトな防御と工学的な安全施設・設備や警報、非破壊検査などのハード防御）が、組織的要因（経営層の意識決定、予算配分、人員配置、計画、意思疎通、管理など)、局所的な作業現場要員（過度のタイムプレッシャー、不適切な道具や装備、訓練不足、人手不足など）によって誘発される従業員の不安全行為によってほころびることで、潜在的だった危険性が顕在化し、それによって組織全体ないし組織の外部にまで損害がもたらされるとする。

しかしこの研究の枠組みは、具体的な対策につなげられる要素を検出しやすいものの、個人、組織、社会の相互作用や時系列的な構造の発展過程が考慮されていない。

➢ A.Gidedens, New Rules of Sociological Method, ,Hutchinson,1976

二元論に依拠する機能主義や解釈主義などの社会文化論の問題点を構造化理論（社会構造（規則と資源）を個人行為によって創られるものである一方で、同時にそのような社会構造を創る個人行為そのものを再帰的に作り出す二重の性格も持つとし、この個人行為と社会構造の創り創られる関係をいう）により記述した。

このフレームワークは、個人、組織、社会の相互作用や構造の発展過程を上手く表現できる基本的な枠組みを与えているが、詐称問題についての言及は見られない。

➢ 間島 崇（2007)「組織不祥事」文真堂

A.ギデンズの構造化理論を組織不祥事に展開し、I.バーリーの時系列での相互作用による構造変化、ミクロ・マクロリンク（個人と社会との相互作用）を包含したモデルを組織不祥事に適用した。その結果、個人と組織、社会の間の創り創られていく組織文化がいつしか歪んで行き組織不祥事に発展していく様子をモデル化した。

ギデンズの枠組みを詐称問題に適用することで詐称の過程を個人、組織、社会の相互作用を時系列的な変化とともに上手く描けるようになっている。しかし、具体的な原因の特定やその効果の定量化ができておらず、具体的な対策の提供力に乏しい。また、「忖度」など日本独特の社会風土の問題を取り込めてはいない。

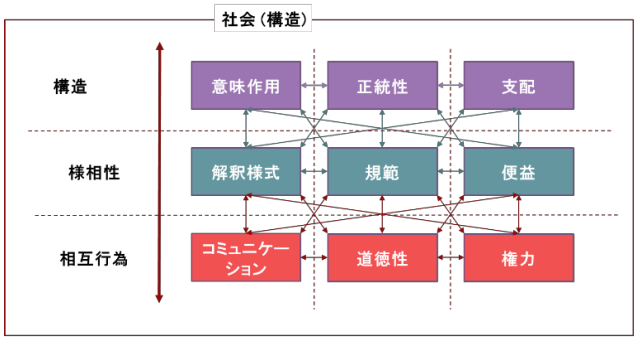

出所：A.Giddens,New Roules of Sociological Method, Hutchison 2nd ed.1993.

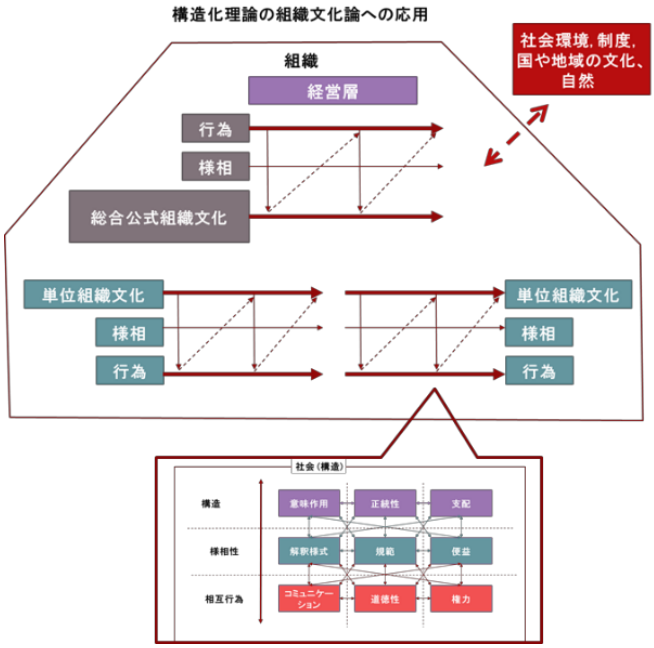

3.3　ビジネスゲームを企業不祥事研究に適用するに当っての課題

ビジネスゲームにおいて、会社内部で行う場合など会社不祥事という性格上、会社や上司などへの尊宅が働く。そのため、発言や判断の信頼性が高いとはいえないケースが発生することが容易に想定されるが、そのことに対する有効な手段が講じられていない。また、対策の有効性を評価する場合、ABM（Agent Based Modeling）を使うことを想定しているがエージェントの行動をどのようなロジックで行うのか決まっていない。

3.4　先行研究に見る評価方法での課題

- Detecting Deceptive Discussions in Conference Calls.David F. Larcker, Anastasia A. Zakolyukina. Journal of Accounting Research. May 2012, Vol. 50, Issue 2, Pages 495–540.
  - この論文では四半期ごとの企業収益報告書をそこに出現する言語パターンや頻度を特徴量とするテキスト分析から、報告内容を「真実」または「詐称」と判定するモデルを構築している。テキスト分析は、これまでの詐称に関する心理学的、言語的研究に基づいており、これを用いて CEO または CFO の記述を評価した結果の推定精度は、ランダムな推測よりも 6-16%優れており、少なくとも財務および会計上の変数に基づくモデルと同等であることが示された。詐称を語る幹部の言葉からは、一般的な知識への言及、肯定的な感情表現の少なさ、株主価値への言及が少ないことが見て取れた。さらに、詐称を語る CEO は、著しくポジティブな発言が多く、逆に不安な言葉を使うことは少なかった。

このように、テキストマイニングを用いて関係者の発言や文書記録を分析することで明示的な表現からでもその裏側にある忖度の可能性を分析できる可能性がある。

- 池田明、海尻賢二(July 2008)「マルチエージェントシミュレーションによる開発を伴う政府調達の制度設計に関する一考察」情報処理学会論文誌, Vol.49.No.7,2731-2740
  - 政府調達における受注者選定において、受注者側への見積もり方法に対してどのような入札制度を制定すれば、適正な企業努力を継続させたまま正しい見積もりを行わせる事が出来るのかをエージェントを用いて検討している。この際、個人（各企業の見積もり担当者）・組織（会社の継続的な利益を目指す経営者層）・社会（発注者としての政府の制度）の相互作用の仕組みを各階層の適応として遺伝的アルゴリズムを用いて再帰的に検討している。

このように忖度に働く種々の要因パラメータ（例えば、個人の承認欲求や自己防衛反応、組織内の組織凝集性、同調性、組織規範や社会制度のもたらす権力による作用）を効用や適合性を定式化できれば GA（遺伝アルゴリズム）による最適化手法の枠組みを適用できると思われる。現状、これらの尺度をどのように定式化すべきか検討中であるが次の文献にあるようにビジネスゲームを用いて検討することが有用な

アプローチであると考えられる。

- 諸藤 秀幸，倉橋 節也，出口 弘 (2008)「ゲーミング手法を用いた官製談合のモデル化の試み」会計検査研究 (37), 115-129, 2008-03

  この論文では、談合をオークション理論に基づきABM（Agent.Based.Modeling）で解析。モデルをゲーム理論の均衡解を用いた談合のない場合と、オークション理論を用いた談合がある場合とを比較し、談合を成立させない条件（発注元の調査費用など談合コストの導入）を検討している。この際、談合のフィクサーがいる場合の効果についてビジネスゲームを用いて実験的にその効果を測定している。

従って、忖度が働く種々の状況をこれまでの詐称事件をもとにビジネスゲーム化し、その結果から要因パラメータと効用関数を導出する事が可能であると思われる。

35. 日本の組織文化の特徴と「赤福事件」に見る企業不祥事への忖度の影響

日本の独特の文化として「おもてなし」や「もったいない」文化が挙げられる。これらは、物や相手へのこまやかな心遣いや慈しみの文化が反映され日本人共通の価値観、文化である。日本社会はよく言われるハイコンテクスト文化の産物であり、相手の言葉の行間や空気を読んで言われなくとも相手の欲することを斟酌して行動をとることが美徳であると考えられている。忖度もその一つであり、言われずとも相手の気持ちを推し量り行動することをいう。しかしながら、このことがしばしば組織の負の文化や権力と結びつき良かれと思われることが結局反社会的な行為、すなわち不祥事になる例が見られる。最近スポーツ界を揺るがす事件となった「日大アメフト部の事件」は記憶に新しい。

今回のモチーフとなった「赤福事件」も同様で、創業者の理念である「二つ売るより一つ残すな」が組織の文化となりその日に売れ残った材料限定で「まき直し」と称して原材料に切り込んでいたが、いつしかかなり経過した売れ残り品を切り込んでいたにもかかわらず製造年月日を偽って表示した事件である。そこには、社会道徳にかなうという善意と会社理念を守り顧客の需要に応えようとする経営者側の意向を「忖度」し、食中毒など問題を起こさないよう生真面目で厳格な品質管理を行うなど組織的に取り組む日本企業には独特な組織文化が存在する。このように、企業不祥事の中には意図的に反社会行為を行ったものだけでなく社会道徳的に叶うむしろ善として行った行為が、いつしか再帰する組織活動のなかで個人や組織として忖度することによって、法制度と社会認識の拡大解釈を繰り返し、組織変容し、不祥事に発展することが、ハイコンテクスト社会の日本ならではの問題として浮かび上がるのである。

4．ビジネスゲームのデザイン

4.1　ビジネスゲーム仕様

ビジネスゲームは、以下のシナリオで複数グループを対象として行うものとする。また、システムについては柔軟にビジネスゲームを開発できる環境として“NetLogo”を用いる。

(1)　忖度ゲームの設定

発生イベントを経営情報として考慮に入れながら、需要に合わせて食品を製造販売して利益を競うゲームである。

- シナリオ
  - ✓ 当該企業は食品会社であり、その経営理念は「顧客第一」と「もったいない精神」である。また今期はその旺盛な需要から売り上げの拡大を経営の重点目標に据えている。
  - ✓ 生産は前月との売り上げと、SNS を中心とした顧客の評価を考慮して決められている。
  - ✓ また、原材料を購入し生産した商品は製造後すぐに店頭に並ぶ。商品の消費期限は 1 週間であるが当日販売で売れ残った商品は味が低下するため売れ残りが多くなるとともに SNS の評判も悪くなり、次月の売り上げに影響する。
  - ✓ そこで現状、当日の売れ残りに限って、原材料への切込み（売れ残りを原材料として混ぜ込んで使用する）を行っているが、賞味期限内では味が落ちるほかは食中毒などの懸念はなく切込み期限の延長も検討している。切込み量は原材料単価に大きな効果がある。
  - ✓ 賞味期限を変更することで売れ残りを減らすことができる。ただし、行政の監査が入り指摘を受けた場合はペナルティが課せられる。
- ゲームの勝敗の決め方
  - ✓ ゲームの勝敗は、グループごとのゲーム各ターンの合計得点で順位を決める。
  - ✓ 得点は、経営方針遵守ポイントと業績目標達成ポイントの合計である。
  - ✓ また、グループとは別に個人ごとの入力に基づ

いた個人ポイントも算出され個人順位がつけられる。

- ✓ ゲーム参加者は、前月の販売実績や SNS の評判から当月の需要を予測し、経営方針を考慮したうえで、毎回生産量と原材料の購入量、売れ残り品の切り込み量を入力する。
- ✓ 経営方針遵守ポイントは経営方針にどれだけ沿った業績値（売り上げ、顧客満足、廃却量）を挙げられるかで決まる。
- ✓ 業績目標達成ポイントは、利益（＝売り上げ－原価）で決まる。

■ ゲーム進行とイベント発生

- ✓ ゲームは、一組 3～5 人のミドル層で複数のグループに分かれて行われる。
- ✓ 経営方針と売り上げ推移などの経営情報に基づき生産量や切込み量を決めていく。
- ✓ 経営情報は他に、売れ残り量と生産日からの経過日数、市場の需要推移、SNS の評価が毎回与えられる。
- ✓ イベントとして、市場の急な需要発生、法改正（賞味期限に影響が出る）、行政の立ち入り検査実施が発生する。
- ✓ ゲームが何回ターンするのかは参加者には知らされない。
- ✓ ゲームの様子はビデオで撮影される。
- ✓ ゲーム終了後、ディブリーフィングが行われる。

以下に、本ゲームフローチャートおよび入力内容、支援システムにより提供される情報の内容を示す。

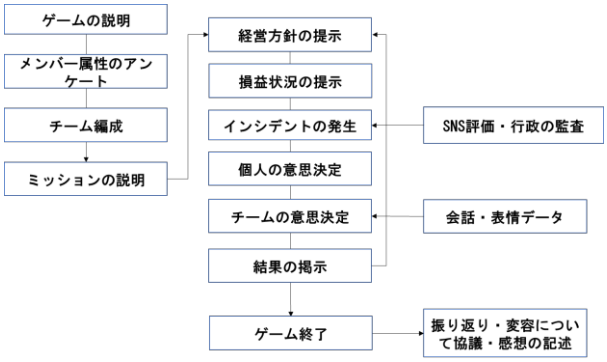

施策	内容
経営方針の順守	経営方針である「もったいない」を遵守し廃却を少なくすると得点であるトップ方針遵守度が上がる。また、「顧客需要に応える」を遵守すると得点が上がる。
生産量	前月までのSNSの評判で生産量を決めるが、当月のSNSの評価により売り上げが変化するので売れ残りが発生する。一定の割合で大口の見込み注文が発生するがその売れ残りを引き取る責任があるので必ずしも全量受ける必要はない。その場合には先のチーム得点は得られない。
材料切込み量を決める	売れ残りを再利用した量。切込み量が多いと原価は下がるが味が悪くなり、SNSの評判が悪くなり次月の売り上げが下がる。切込みは週一回までである。
廃却量	売れ残り—切込み量。廃却が増えるとSNSで悪い評判が立ち売り上げが下がる。
原価	切り込みが多いと好転する。
売れ残り品販売評価損	売れ残り品を販売すると売値を下げなければならない。売れ残り品は売れない可能性が高まる。
SNSによる売り上げ効果	即日販売、廃却が少ないと良い評判が立ち次月の売り上げが伸びる。切込み量が増えると味が悪くなり評価が下がり次月の売り上げが減る。
再利用と消費期限表示	切り込み材が古いものは消費期限を短くしなければならない。味が落ち、売り上げが下がるほか売れ残りも出やすい。変えなくとも食中毒の恐れはないが、監査でばれると大きな罰金を支払う。

表示情報項目	内容
行政機関からの監査および通告	監査の発生やその結果によりペナルティーを通告する。
前月売上数量	前月の切込み量と経過日数から売り上げ量を計算し表示する。
損益シート	各チームの損益を算出し表示する。
チーム得点集計	損益と経営方針遵守による得点合計が示される
売れ残り量	売れ残り経過に数に対応する売れ残り量を表示する。
原価	切込み量が多いほど原価は下がるが、生産日からの経過日数が多いものを使う場合は保管料がかかるため原価低減寄与が小さくなる。計算結果を表示する。
SNSの評判	各チームの味と廃却に関する評判が示される。売れ残り材の再利用による味の低下による売り上げ量の減少をもたらす。また廃却量が増えると評判が下がりこれも売り上げ低下を招く。

(2) ゲームにおける忖度の評価方法

忖度とは、日本のハイコンテクスト社会を前提とし指示されずとも相手の気持ちを推し量り応えようとすることである。このゲームでは参加者個人が、相手である経営者やグループ員の意向をくみ取り直接指示された以上に応えようと本来顧客（味や鮮度）や業績（利益）に相反する切込み量や期限を延長するとこに相当する。従って、忖度の大きさは意思決定におけるこれらの数字の大きさ、個人の判断とグループ判断の差で示されると考えられる。

そこで、忖度の評価方法としては、

- ✓ 切込み量の大きさ（原価への寄与が少ないにもかかわらず大きくとっていれば「もったいない」を社是とする文化を忖度していると考えられる）
- ✓ 経営方針遵守ポイント（勝敗を決定するうえでは業績ポイントと比較して小さいにもかかわらずこれに偏った判断を行う）
- ✓ 個人ポイントとグループポイントの差（グループ即ち組織への忖度）

(3) 忖度の指標としてのカルバック・ライブラー情報量

カルバック・ライブラー情報量は

P、Q を離散確率分布とするとき、P の Q に対する**カルバック・ライブラー情報量**は以下のように定義される。

$$\sum \mathrm{Pi} \log \frac{Pi}{Qi}$$

ここで P(i)、Q(i) はそれぞれ確率分布 P、Q に従って選ばれた値が i の時の確率である。

カルバック・ライブラー情報量は、Pi をデータ i を知った後の確率、Qi をデータ i を知る前の確率とした時のデータ i を知る前後の情報量の差、(-logQi(x)) -(-logPi(x)) としてこれらの平均値をとったものである。

上述の忖度を経営者や社是、グループの決定を知る前後の差ととらえればこのカルバック・ライブラー情報量で記述することが可能であると考えられる。

(4) 表情による忖度の評価の可能性に関する検討

2.2 に述べたように、被験者の回答は信頼性が十分でない可能性があり、変容した後のディブリーフィングでは変容する過程でのリアルタイムの忖度の発生を通した組織変容は記述することが困難である。そこで、先に述べたビデオデータを利用した表情分析が有効であると思われる。表情分析では AZURE による分析がいくつか報告されておりこの枠組みでの分析を本研究に供することができると思われる。

5. 今後の課題

今後はこれらを一連のゲームシステムとして NetLogo を用いて作製し、実際にこれらのゲームを実験として行いその有効性を評価確認する。更に、ゲーム中及びゲーム後のディブリーフィングで被験者の表情を AZURE の表情分析で解析し、これらの結果とゲーミングの結果を比較することで忖度と表情がどのような関係になるのかを明らかにする予定である。

6. 参考文献

- Donald R. Cressey(1973), Other People's Money (Montclair: Patterson Smith, 1973) , 30.
- 大倉真人(2001)「保険会社のモニタリングに関する一考察--保険金詐欺発生メカニズムに関するゲーム論的分析」生命保険論集,生命保険論集 ,(136), 231-270, 2001-09
- 脊板弘康(2018)「工程エンジニアの問題解決方法選択行動にみる品質偏重傾向に関する研究」,筑波大学大学院修士論文,2018
- Detecting Deceptive Discussions in Conference Calls.David F. Larcker, Anastasia A. Zakolyukina. Journal of Accounting Research. May 2012, Vol. 50, Issue 2, Pages 495–540.
- 島崎敏一.「ゲーム理論による談合の分析」建設マネジメント研究論文集 4, 21-28, 1996Japan Society of Civil Engineers
- 池田明、海尻賢二(July 2008)「マルチエージェントシミュレーションによる開発を伴う政府調達の制度設計に関する一考察」情報処理学会論文誌, Vol.49.No.7,2731-2740
- 小林知己、高橋聰等「組織逸脱度と改善と分岐条件とそのハーネシングに関するエージェントシミュレーション」電気情報通信学会論文誌,D,Vol.J94-D No.11pp.1825-1835,電気情報通信学会 2011
- 諸藤 秀幸 , 倉橋 節也 , 出口 弘 (2008)「ゲーミングの手法を用いた官製談合問題のモデル化の試み : 制度設計分析の基礎付けを目指して」会計検査研究 (37), 115-129, 2008-03
- 榎本博明 (2017)「『忖度』の構造～空気を読みすぎる部下、責任を取らない上司」,イースト書籍
- 片田珠美 (2017)「忖度社会ニッポン」, 角川新書
- 島崎敏一,「閾値モデルによる談合の成立可能性の分析」,建設マネジメント論文集, vol.5, 1997
- 太田肇(2017) 「日本型組織と不祥事―「管理強化」がなぜ裏目に出るのか」日本経営学会編『日本の経営学９０年の内省と構想』経営学論集第８７集,2017 年４月, 82-89
- 下平利和・寺野隆雄(2004)「ビジネスゲームを通じたケースメソッドへの接近-筑波大学経営システム科学専攻における「社長のジレンマ」モデル実戦の経験から」シミュレーション＆ゲーミング, ,Vol.14,No.2,December,144-156
- 中野健次・寺野孝雄(2007)「ケースとビジネスゲームとの融合―ビール会社経営における意思決定の学習―」シミュレーション＆ゲーミング,Vol.16,No.1,June,13-27

機械学習を用いた高級焼肉店における顧客の購買データ分析に関する研究

Research of High-end Barbecue Beef Restaurants Based on Consumer Purchase Data by Machine Learning

辛　郷孝[1]、菅　愛子[1]、山下　泰央[1]、高橋　大志[1]

Kiyotaka Shin[1], Aiko Suge[1],Yasuo Yamashita[1], Hiroshi Takahashi[1]

[1]慶應義塾大学 大学院経営管理研究科
[1]Graduate School of Business Administration, Keio University

要旨：本研究は、外食産業の POS データを用いて経営力向上に繋げるサービスの実現を目的としている。日本の外食産業は、労働生産性が低い上、慢性的な人手不足で人材確保に苦労している。そこで、この課題を解消する対策として、1 テーブルごとの客単価向上が有効と仮説を立て、客単価の高い高級焼肉店の POS データを分析した。商品を提供する顧客層ごとに購買行動の特徴を明らかにし、機械学習を用いて販売政策の検討を行う。

Abstract: This research aims to improve the services of the food-service industry so it can lead to better management.The labor productivity of the food-service industry in Japan is very low, has long suffered from lack of personnel and continues to struggle maintaining talent. Therefore, as a measure to solve this problem, we analyzed the POS data of a luxury barbeque shop with a high customer unit price, making a hypothesis that the improvement per customer price per customer is effective.And clarifying the purchasing behavior of each product target using Machine Learming.

1. 先行研究

外食産業の市場規模は、2016 年時点で約 25 兆円の規模となっており、労働者人口約 480 万人、ここ 2 年間は日本の人口が減少しているにもかかわらず、連続で微増している巨大な市場である。しかしながら、日本の外食産業は、労働生産性が低い上、慢性的な人手不足で人材確保に苦労している。これまで、外食産業及びサービス産業における生産性の向上など多くの実証研究がなされてきた。近年では、先端研究所と協業し、外食業界に科学的経営手法を取り入れる取り組みが進んでいる[1] [2]。

本研究は、外食産業の POS データを対象とした分析を行う。とりわけ本分析では、高級飲食店の POS データを対象とし、顧客単価の高い顧客に焦点をあてた分析である。このような顧客単価の高い高級飲食店を対象とした分析は、我々の知る限り限定的である。次節において目的について触れたのち、データ、分析方法について説明する。5.は分析結果、6.はまとめである。

2. 目的

本研究では、高級焼肉店を利用する顧客層の特定および各顧客層が、どのような注文を行っているのかを、購買データ分析を通じ明らかにすることを目的とする。主成分分析によりデータのパターン分析を行い、クラスター分析から会計ごとのセット商品の購買分析を行った。分析結果から各顧客層ごとの特徴をつかみ、高級焼肉店を経営する企業の経営指標として、意思決定の一環として利用することに貢献できる可能性がある。更に、リアルタイムで POS データ分析を行い、経営の意思決定に利用することができれば、外食業界の経営力向上につなげるサービスの実現が可能となる。これまでの日本ではデフレ経済が長く続き、低価格でのサービス提供を行うために、コスト削減、オペレーションの効率化、人件費削減に主眼を置いてきた。しかし、働き方改革が提唱されている中、外食産業での属人的な経営スタイルからの脱却を行い、高級外食店が POS データを活用した経営、先端技術科学を経営に用いることで、外食産業の付加価値を高め、業界全体へインパクトを与えるきっかけとなることが期待される。

連絡先：慶應義塾大学 大学院経営管理研究科
〒223-8526　横浜市港北区日吉 4-1-1
E-mail: k-shin@keio.jp

3. データ

POS データについては該当飲食店の共同研究の了承の元、SoftTheater 社から取得した。本研究は、2017 年 8 月 1 日-2018 年 7 月 31 日までの 361 日間において、高級焼肉店 1 店舗の POS データから 1 会計ごとのオーダーデータを抽出し分析を行った。**表 1** は上記 361 日のデータである。17,855 件の会計ごとのデータであり、160,125 件の注文データである。また、該当店舗のネットロコミ数は、284 件である。(出典:食べログ 168 件, ぐるなび 2 件, Retty114 件)

表 1：POS データ件数

データ取得日	361 日	
会計件数	17,855 件	1 テーブルごと
注文件数	160,125 件	1 注文ごと

図 1：ネットによる商品口コミ分析

4. 分析方法

高級焼肉店に来店する顧客は、事前予約をして来店するケースが多い。あらかじめ来店日、来店時間、テーブル番号を予約時に予約管理システムに登録する。当日は、顧客をテーブルに通し、店舗スタッフは、新規オーダーを登録する。その際に、テーブル番号を選択し、来店客の人数、性別などを入力するとオーダー開始できるシステムとなっているため、瞬時に顧客構成のデータが蓄積される仕組みとなっている。このテーブルごとのオーダーを分析し、時間別、顧客構成別、温度別、支払方法別の購買データの分析を行った。また、ネットロコミ情報と実際の注文データとの関連性に注目し、分析を行った。

5. 分析結果

最初に顧客構成ごとの来店組数を分析した。**表 2** は、その結果である。高級焼肉店の顧客構成は 2 人で来店する組数が 10,733 件（60.11%）と圧倒して多く、その中でも男性 1 名＋女性 1 名で来店する組数が 6,568 件(全体の 36.79%)という結果が得られた。

表 2：顧客構成別客単価　組数上位 6

顧客構成	組数	平均	中央値	標準偏差
男 1 女 1	6,568	5,663 円	5,325 円	3,377 円
男 0 女 2	2,896	3,249 円	2,320 円	3,054 円
男 2 女 0	1,269	6,573 円	6,185 円	4,273 円
男 0 女 3	663	3,331 円	2,600 円	2,259 円
男 4 女 0	634	8,415 円	8,735 円	3,243 円
男 2 女 2	627	6,676 円	6,650 円	3,552 円

しかし、客単価が高い顧客構成は、男性 4 名＋女性 0 名の組み合わせである。これらのオーダーの詳細について分析を行った。次に、入店時間別の分析を行い、全体での客単価と 17 時以降の客単価にどのような変化があるのか分析を行った。また、最高温度、最低温度、降雨量などと売上との相関関係の分析や、ネット上のロコミ情報から、商品名に絞り、出現頻度と実際のオーダー数の分析を行った。

6. まとめ

本研究では、高級焼肉店の POS データを分析し、顧客の購買データを分析した。分析の結果、購買顧客のクラスターの存在および、各クラスターごとの特徴を明らかにすることができた。また、ネットのロコミに上がる商品と実際の購買数の相関関係があることが認められた。今後の課題としては、新規顧客とリピータ客の購買データの比較分析を行う必要がある。また、POS、顧客管理のデータ分析を通じた日次経営指標の作成およびキャッシュレスなどのフィンテック領域への応用も、今後の課題として挙げられる。

参考文献

[1] 星野智洋, 谷﨑隆士, 新村猛, 竹中毅：機械学習を用いた飲食店運営の効率化へのアプローチ, 人工知能学会 32 回(2018)
[2] 原田奈弥, 山下和也, 本村陽一：ID 付 POS データによる購買行動の季節変化の分析 SIG-SAI/SIG-SAI,27(7),1-7 (2016-11-11)
[3] 石垣司, 竹中毅, 本村陽一：日常購買行動に関する大規模データの融合による顧客行動予測システム, 人工知能学会論文誌, 26 巻, 6 号, D, pp. 670-681, (2011)
[4] 神嶌敏弘：推薦システムのアルゴリズム(1), 人工知能学会誌　22 巻 6 号(2007 年)

機械学習によるオートオークション落札価格の予測

Price Prediction of Used Cars at Auto Auction by Machine Learning Methods

櫻井 大宙 [1*]　速見 勇磨 [1]　山下 梨瑳 [1]　長谷川 恵理子 [2]
下山 力三 [2]　福西 亮介 [2]　黛 広樹 [2]　鈴木 智也 [1, 3]
Hiromichi Sakurai[1], Yuma Hayami[1], Risa Yamashita[1], Eriko Hasegawa[2],
Rikizou Shimoyama[2], Ryosuke Fukunishi[2], Hiroki Mayuzumi[2] and Tomoya Suzuki[1, 3]

[1] 茨城大学大学院理工学研究科
[1] Graduate School of Science and Engineering, Ibaraki University
[2] 株式会社プロトコーポレーション
[2] PROTO CORPORATION
[3] コラボウィズ株式会社, [3] CollabWiz, Inc.

Abstract: Buyers of used cars have to predict their dealing prices at auto auction held after about one month, but it is very difficult to predict them because each condition of used cars is completely different such as mileage, model year, body color, etc. For this reason, we propose two prediction methods: as the first one, we consider the median of dealing prices in each car model as a base price and predict its future price by time-series models: ARIMA and SARIMA. After that, the predicted bace price is converted into the individual price of each used car by the machine learning method that learned the relationship between the condition of used cars including individual prices and the bace price. As the second method, we adopt the deep learning approach to directly predict individual future prices of used cars without using the base price, but using all the information attached to each used car as explanatory variables. To verify the usefulness of our proposed methods for a used car assessment system, we performed some prediction tests using the real auto-auction price data.

1　はじめに

中古車はユーザーから買取店へ流れた後，主にオートオークション [1] を通じて販売店に売却される．買取店の立場に立てば，買取からオートオークションに出品するまで一ヶ月は要するため，翌月の競買価格を予想して買取査定価格を設定する必要がある．そこで株式会社プロトコーポレーション (以下，プロト社) では，翌月に開催されるオートオークションでの落札価格を考慮した査定システムを製作し，中古車買取店が査定価格を決定する際の情報提供を行っている．

しかし中古車の流通価格を予測することは大変難しい．その理由として，中古車は走行距離や車検残月といった特徴が個車ごとに異なり，唯一無二の存在である．そこでプロト社の査定システム [2] では，まず対象個車と同一車種の落札実績を踏まえ，翌月の該当車種の指定条件の価格（代表価格）を推論し，さらに対象個車の状態（説明変数）に基づいて個車の落札価格へ変換するといった，2 段階のプロセスを経る．各プロセスでは主にパラメータを与えて機械的に推論するが，不合理な結果を訂正するために人間が有する柔軟な推論能力を駆使し，フレーム問題に対処する場合もある．しかし本研究では，全て機械的に推論することで全自動かつ主観が介在しない予測システムを構築したい．

まずはプロト社のように 2 段階のプロセスに分割し，代表価格の予測には時系列モデルを，個車価格への変換には機械学習モデルを適用する．しかし代表価格の予測誤差がその後の変換に悪影響を及ぼすため，個車の落札価格を直接予測する深層学習モデルについても検討する．直接予測では個車の有する全特徴量を説明変数とするため高次元の機械学習となるが，積層オートエンコーダを事前学習に適用することで次元圧縮（特徴選択）を行う．

*連絡先： 茨城大学大学院理工学研究科 茨城県日立市中成沢町 4-12-1 E-mail: 17nm920a@vc.ibaraki.ac.jp

2 問題設定と用いるデータ

中古車取引の流れは次の 4 つに分類される．(1) 買取店が顧客から中古車を買い取る，(2) 買い取った中古車を買取店がオートオークションに出品する，(3) 販売店が中古車を落札する，(4) 販売店が顧客に中古車を売却する．本研究では中古車買取店の立場に立ち，(3) での落札価格を考慮しつつ，(1) にて合理的な買取価格を決めるための方法論を検討する．もし買取価格を高く見積もれば買取店の利益が減り，低く見積もれば顧客が他店に流れる可能性がある．また買い取りからオートオークションへの出品まで整備等に一週間から一ヶ月程度のタイムラグを要すため，(1) の時点で (3) での落札価格を予測する必要がある．

本研究の予測対象として,「セダン」「コンパクト」「ミニバン」「ＳＵＶ」「軽自動車」の 5 カテゴリから,「ＬＳ」「プリウス」「フィット」「デミオ」「セレナ」「パジェロ」「フォレスター」「タント」「ワゴンＲ」の 9 車種を選出した．プロト社が有するオートオークションデータは，オートオークション会場が検査した個車の状態を表す多変量データで構成されている．その一例として「落札価格」「走行距離」「車検満了年月」「修復歴」「内装評価」などが挙げられる．またマスターデータとして,「車種」「モデル」「型式」「グレード」に応じた「キーコード」「公称性能」「オプション装備」「新車価格」に関する情報も利用できる．このキーコードが自動車を分類する最小単位であるため，オートオークションデータからキーコードを紐付けてマスターデータから情報を抽出する．

3 代表価格の時系列予測

3.1 時系列予測モデルの適用

オートオークションにて中古車が落札されるのは買取店が査定買取してから一ヶ月程度先であることが多く，買取店は中古車を査定するときに翌月の落札価格を予測する必要がある．この予測には査定当月までのオークション落札情報を参考にするが，前述のとおり対象車両と同一条件の過去実績は存在しないため，統計的に推論することができない．そこで本章では充分なサンプル数を確保するために，個車ではなく車種毎に落札価格をトラッキングする．また車種の代表価格として，落札価格の中央値を機械的に用いる．

次に，翌月の代表価格（中央値）を予測するために，過去の代表価格を用いて時系列モデルを学習する．中古車は流行などの「トレンド要因」や新学期需要などの「季節性要因」が影響すると考えられる．これらの非定常要因に対する時系列モデルとして，本研究では自己回帰和分移動平均 (ARIMA) モデルと季節自己回帰和分移動平均 (SARIMA) モデルを適用する．

時刻 t におけるある車種の代表価格（中央値）を X_t と書くと，ARMA(p,q) モデルは次式となる．

$$X_t = \sum_{i=1}^{p} a_i X_{t-i} + \epsilon_t + \sum_{i=1}^{q} b_i \epsilon_{t-i} \tag{1}$$

ここで，a_i は過去の実現値 X_{t-i} における時間記憶力，b_i は過去のホワイトノイズ ϵ_{t-i} における時間記憶力を示す．ARMA モデルは定常性を仮定するため，上記の非定常要因を表現できない．X_t のトレンド要因について d 階差分をとり，季節性要因について D 階季節差分を取ることで定常化処理を施す．なお X_t は月次データであるため，季節周期は $s = 12$（12ヶ月）とする．その後，定常化済み $\Delta^d \Delta_s^D X_t$ について式 1 の ARMA モデルを適用し，推定された $\Delta^d \Delta_s^D \hat{X}_{t+1}$ を逆算することで $\hat{X}_{t+1}$ を得る．式 1 では時間系列に関する記憶性を表現できるため，ARIMA(p,d,q) モデルと等価である．

しかし季節周期 s をまたぐ時間記憶性も表現するには，次式の SARIMA$(p,d,q)(P,D,Q)[s]$ モデル [3] を用いる．

$$\begin{aligned}\Delta^d \Delta_s^D X_t &= \sum_{i=1}^{p} a_i \Delta^d \Delta_s^D X_{t-i} + \sum_{I=1}^{P} A_I \Delta^d \Delta_s^D X_{t-sI} \\ &\quad - \sum_{i=1}^{p}\sum_{I=1}^{P} a_i A_I \Delta^d \Delta_s^D X_{t-sI-i} + \epsilon_t + \sum_{j=1}^{q} b_j \epsilon_{t-j} \\ &\quad + \sum_{J=1}^{Q} B_J \epsilon_{t-sJ} + \sum_{j=1}^{q}\sum_{J=1}^{Q} b_j B_J \epsilon_{t-sJ-j}\end{aligned} \tag{2}$$

上記と同様に，推定された $\Delta^d \Delta_s^D \hat{X}_{t+1}$ を逆算することで $\hat{X}_{t+1}$ を得る．ただしモデル構造が複雑であるため，学習に伴うデータ不足および過学習の問題が懸念される．モデル次数については AIC を最小化するように決定するが，過学習の観点からよりシンプルな ARIMA モデルの方が機能する可能性もある．

3.2 予測実験

2011 年 10 月から予測対象の前月までの代表価格を用いて時系列モデルをオンライン学習し，2016 年 1 月から 2017 年 9 月を予測対象とした．予測精度の評価には，正規化平均二乗誤差 (NMSE) と正答月数を用いた．NMSE は次式で得られる．

$$\mathrm{NMSE}(\hat{X}) = \frac{\sqrt{\sum_{t=1}^{T}(X_t - \hat{X}_t)^2}}{\sqrt{\sum_{t=1}^{T}(X_t - \bar{X})^2}} \tag{3}$$

表 1: ARIMA モデルによる代表価格の予測結果

カテゴリ	車種	NMSE	正答月数
セダン	ＬＳ	0.559	17
セダン	プリウス	0.621	19
コンパクト	フィット	0.552	15
コンパクト	デミオ	0.546	14
ミニバン	セレナ	0.629	18
ＳＵＶ	パジェロ	1.613	14
ＳＵＶ	フォレスター	1.062	9
軽自動車	タント	0.454	19
軽自動車	ワゴンＲ	0.913	15

表 2: SARIMA モデルによる代表価格の予測結果

カテゴリ	車種	NMSE	正答月数
セダン	ＬＳ	0.466	20
セダン	プリウス	0.797	18
コンパクト	フィット	0.631	15
コンパクト	デミオ	0.515	15
ミニバン	セレナ	0.666	18
ＳＵＶ	パジェロ	1.127	17
ＳＵＶ	フォレスター	1.004	11
軽自動車	タント	0.451	19
軽自動車	ワゴンＲ	0.850	17

ここで，T は予測対象の期間の長さ，X_t は時刻 t における代表価格の真値，$\hat{X}_t$ は時刻 t における代表価格の予測値，$\bar{X}$ は期間 $t = 1, 2, \cdots, T$ における X_t の平均値を示す．正答月数は，$\hat{X}_t$ が X_t の $\pm 10\%$ に収まった場合を正解とみなし，予測対象の 21ヶ月間 $(T = 21)$ のうち正解した月数を示す．

予測結果を表 1,2 および図 1~3 に示す．セダンは ARIMA モデルと SARIMA モデルの両方において正答月数が多く，NMSE も低い値となった．理由として，セダンのトレンドは比較的落ち着いており，季節性についても変動幅が他車種より小さい．一方，趣味性が高いＳＵＶはトレンド変化が激しく，季節性変動幅も大きいため予測が難しい．その結果，正答月数は少なく，NMSE も高い傾向にある．特に図 2 において，予測値が真値を 1ヶ月遅れて追いかけている期間が見られる．なお ARIMA モデルと SARIMA モデルの比較においては，特記するほどの差は見受けられない．

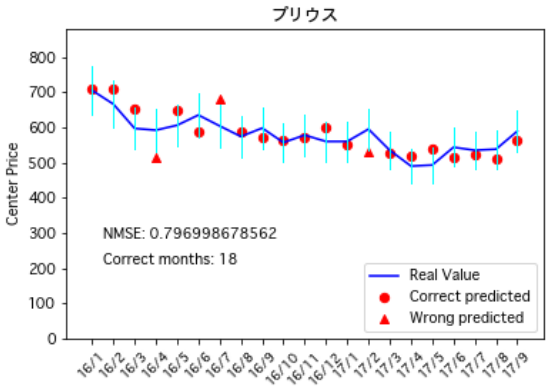

図 1: SARIMA によるプリウスの代表価格の予測推移

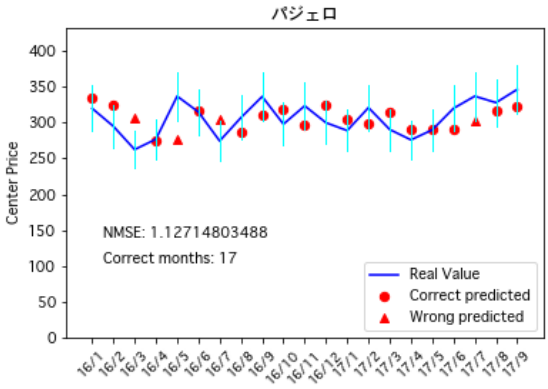

図 2: SARIMA によるパジェロの代表価格の予測推移

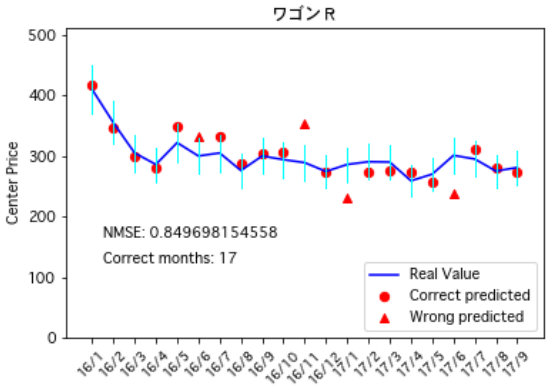

図 3: SARIMA によるワゴンＲの代表価格の予測推移

4 機械学習による個車価格への変換

4.1 ランダムフォレストの適用

次に，代表価格 (中央値) の予測値を個車価格へ変換する方法を検討する．個車の特徴量と代表価格の予測値を説明変数とし，個車の落札価格を被説明変数にすれば，両変数の関係を過去の実績に基づいて機械学習すれば良い．その機械学習モデルとして，本章ではランダムフォレスト [4] を用いる．

その学習手順として，まず N 個の学習データ $(\boldsymbol{x}_i, y_i)$, $(i = 1, 2, \cdots, N)$ から復元抽出し，同サイズ N のデータ集合 $W^{(b)}$ を B 組生成する．次に，それぞれのデータ集合 $W^{(b)}$, $(b = 1, 2, \cdots, B)$ を用いて回帰木 $RT^{(b)}$ を学習する． 回帰木は単体でも連続的な被説明変数の予測に適用できるが，ランダムフォレストは全ての回帰木の予測値を平均化することで予測性能を高めるアンサンブル学習 [5] の一種である．各回帰木の独立性が高いほど予測性能が高まることは集合知の観点（多様性予測定理）から説明できる [6].

4.2 変換実験

学習データの期間は 2016 年 1 月から 2016 年 12 月まで，テストデータの期間は 2017 年 1 月から 2017 年 9 月までとする．まず学習データを用いてランダムフォレストを構築する．その際には，個車情報として「車体色」「年落ち度」「走行距離」「車検残月」「評価点」「新車価格」「ナビの有無」「レザーシートの有無」「サンルーフの有無」を用い，さらに当該車種の代表価格（中央値）を説明変数とする．被説明変数には同車両の「落札価格」とすることで，車種毎に代表価格から個車の落札価格に変換するルールを学習する．その後，代表価格を 3 章で得た予測値に変更し，これを学習済みランダムフォレストに入力することで，個車の落札価格の推定値を得る．この推定はテストデータに対して実施する．

推定精度を評価する指標として，正答率と決定係数を用いる．正答率は，推定値 $\hat{y}_n$ が真値 y_n の $\pm 10\%$ 以内に収まった場合を正解とし，その回数を推定実施回数 N で割ったものである．さらに決定係数 R^2 は次式で得られる．

$$R^2 = 1 - \frac{\sum_{n=1}^{N}(y_n - \hat{y}_n)^2}{\sum_{n=1}^{N}(y_n - \bar{y})^2} \tag{4}$$

ここで $\bar{y}$ は真値 y_n の平均値である．決定係数 R^2 は 1 に近いほど回帰問題として当てはまりが良いことを意味する．

表 3: ランダムフォレストによる個車落札価格の推定結果

カテゴリ	車種	正答率	決定係数 R^2
セダン	ＬＳ	0.3068	0.8802
セダン	プリウス	0.4338	0.8921
コンパクト	フィット	0.2332	0.8933
コンパクト	デミオ	0.3222	0.9433
ミニバン	セレナ	0.3186	0.9328
ＳＵＶ	パジェロ	0.3291	0.9122
ＳＵＶ	フォレスター	0.4076	0.9549
軽自動車	タント	0.4724	0.9516
軽自動車	ワゴンＲ	0.4269	0.9454

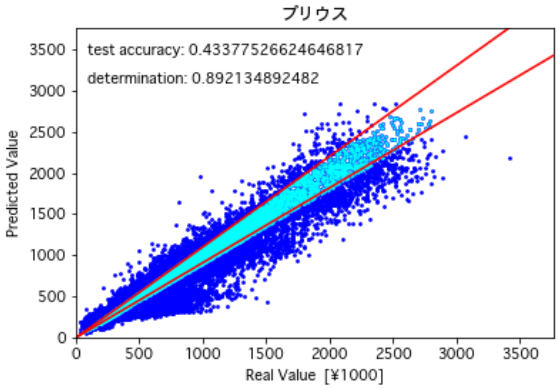

図 4: 個車落札価格の真値と推定値の相関図 (プリウスの場合)

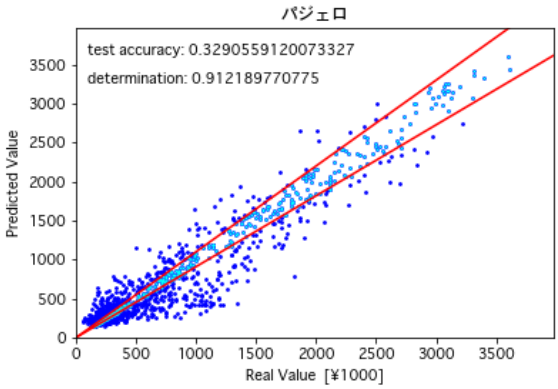

図 5: 個車落札価格の真値と推定値の相関図 (パジェロの場合)

推定結果を表 3 および図 4,5 に示す．いずれの車種も決定係数 R^2 は 0.9 に近い値を示しており，回帰問題としての推定精度は高い．しかし正答率は 0.30 前後と低く，真値の ±10% 以内を正解とみなす基準は非常に厳しい．

また図 4 と図 5 に示すように，低価格帯において誤差が大きい傾向にある．この理由として，グレードや年式などで分類せずに学習したため，高価格帯と低価格帯の学習誤差が同一に扱われたためと考えられる．真値と誤差の比率を考えれば，低価格帯はこの比率が大きくなりやすい．これが正答率を下げる要因になるため，今後は絶対誤差でなく「誤差率」を最小化するようにモデルパラメータを機械学習する方法を検討する．また，グレードや年式などで学習データを分割する方法も有効かもしれないが，学習データ数の減少により機械学習自体の性能が低下する可能性もある．

5 深層学習による個車落札価格の直接予測

5.1 深層学習の適用

3 章と 4 章による予測プロセスにおいて，誤差が発生する要因は 3 点ある．まず車種毎の代表価格として中央値が妥当なのか疑問が残る．しかし機械的に代表価格を求めるルールを定めても，そのルールが完全に正しいとは限らない．次に代表価格に対する時系列予測についても予測誤差が生じ，さらに個車落札価格への変換においても変換誤差が生じる．そこで本章では，これらの誤差が介在しないよう代表価格を考慮せず，直接的に個車の落札価格を予測する．この予測に深層学習モデルを適用する．

深層学習モデルの構成として中間層を 3 層とし，各ニューロン数を下位層から順に $j = 40, k = 8, l = 4$ とする．なお過学習を抑えるべく，中間層第 1 層には消去率 40% のドロップアウトを適用する．活性化関数については，中間層第 1 層と第 3 層に正規化線形関数 (以下，ReLU) を用い，中間層第 2 層に恒等関数を用いる．なお本研究は回帰問題 (連続値の予測) であるため，出力層の活性化関数も恒等関数とする．結合強度の初期値については，ReLU を用いる層へ結合する場合は Xavier Glorot の初期値 [7] を，恒等関数を用いる層へ結合する場合は He の初期値 [8] を用いる．

中間層を多層にするほど勾配消失問題が起こるため，事前学習として積層オートエンコーダ [9] を適用する．各オートエンコーダにおいて情報圧縮することで，説明変数の特徴抽出を行う．その後ファインチューニングとして，深層学習モデル全体を誤差逆伝播法によって再学習する．その際には，教師信号に対する二乗和誤差を誤差関数 E とし，学習データをランダムに 1% 選ぶバッチ学習を 10000 回繰り返す．勾配降下法の最適化アルゴリズムには Adam[10] を用い，各パラメータを $\alpha = 0.001$，$\beta_1 = 0.9$，$\beta_2 = 0.999$ とした．ファインチューニングにおいては勾配消失問題により入力層付近の重みは更新されにくいが，事前学習において優先的に学習されているため重大な問題とはならない．

5.2 直接予測実験

学習データとテストデータの期間は 4.2 節と同様である．説明変数として「車体色」「年落ち度」「走行距離」「車検残月」「評価点」「新車価格」「ナビの有無」「レザーシートの有無」「サンルーフの有無」を用い,「個車落札価格」を被説明変数とする．4.2 説との違いは，代表価格を説明変数に含めない点と，被説明変数の値を「査定時点に戻して」学習する点にある．例えば，年落ち度は予測対象個車の年式とオートオークション開催月の差を意味する．そこで年落ち度を 1ヶ月引いて査定時点の情報を深層学習に入力することで，1ヶ月先のオークション開催時点の落札価格 (予測値) を出力する．

さらに各変数のスケール調整 (前処理) として,「車体色」は車種毎の出現率として定量化し，色の価値 (人気度) を表す.「年落ち度」や「走行距離」は車種毎に学習データの全車両の間で標準化する.「車検残月」は通常満期が 2ヶ年なので査定時点における車検残月を 24 で除しておく．なお新車の初車検は 3ヶ年なので値は 0 ∼ 1.5 をとりうる.「評価点」はオートオークション会場による価値評価であり，新古車は 2000 点，中古車は 300 点 ∼900 点で採点される．そのため元の評価点を 1000 で除しておく.「新車価格」は車種毎に標準化する．さらに「ナビの有無」「レザーシートの有無」「サンルーフの有無」については新車時の標準装備状態と同一であれば 0，不足していれば-1，増設されていれば+1 とする．

予測結果を表 4 および図 6,7 に示す．セダンについては，表 3 のランダムフォレストより高い予測精度を得ている．これは 3 章の時系列予測と同様に，トレンドや季節性変動が比較的小さいほど予測しやすく，さらに直接予測により誤差が介在する要因を減らした効果だと考えられる．決定係数 R^2 においても，9 車種中 5 車種において表 3 を上回る結果を得たが，正答率では 9 車種中 2 車種しか表 3 から向上できていない．この理由として，深層学習の説明変数にトレンドや季節性に関する情報を用いなかったため，これらの要因が強い車種においては前章の方法論の方が機能したと考えられる．そこで今後は，トレンドについては RNN や LSTM など時間構造に対応した機械学習モデルを導入し，季節性については月や曜日などをダミー変数で与える方法を検討する．

表 4: 深層学習による個車落札価格の予測結果

カテゴリ	車種	正答率	決定係数 R^2
セダン	ＬＳ	0.4205	0.9420
セダン	プリウス	0.4492	0.9306
コンパクト	フィット	0.2283	0.8915
コンパクト	デミオ	0.2762	0.9328
ミニバン	セレナ	0.3182	0.9422
ＳＵＶ	パジェロ	0.3093	0.9340
ＳＵＶ	フォレスター	0.3593	0.9707
軽自動車	タント	0.4086	0.9374
軽自動車	ワゴンＲ	0.3941	0.9400

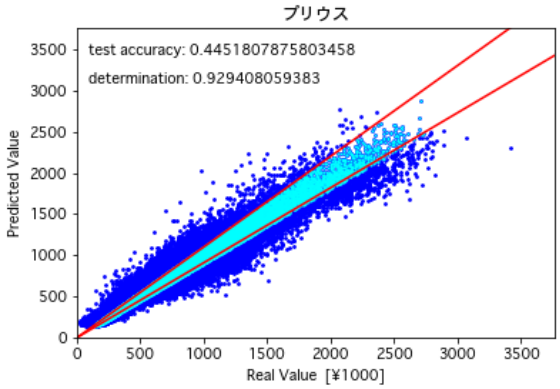

図 6: 個車落札価格の真値と予測値の相関図 (プリウスの場合)

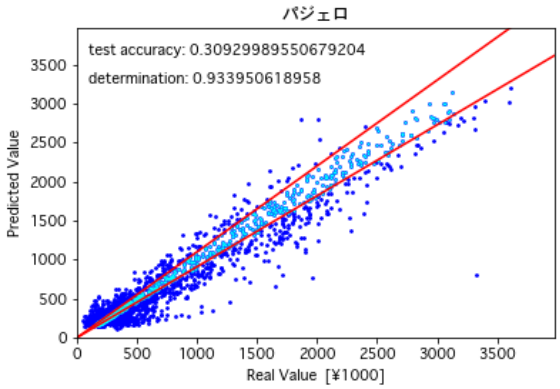

図 7: 個車落札価格の真値と予測値の相関図 (パジェロの場合)

6 まとめ

本研究では中古車買取店の立場に立ち，1ヶ月後の中古車の落札価格を予測した．その際に車種毎の代表価格 (中央値) を媒介する方法と，媒介せずに直接予測する方法を検討した．その結果，トレンドや季節性変動が大きい車種には前者が良く，小さい車種には後者が良かった．この理由として，後者の直接予測 (深層学習) は誤差の発生プロセスを最小限にできるが，前者 (時系列モデル) のように時間構造を考慮していない．そこで今後の課題として，RNN や LSTM でトレンドを考慮し，ダミー変数で季節性を表現し，さらに誤差率を機械学習の評価基準にすることで低価格帯における予測誤差の改善を目指す．

謝辞

本研究は株式会社プロトコーポレーションとの共同研究である．なお本研究の一部は文部科学省科学研究費基盤研究 (C)(No.16K00320) の助成により行った．

参考文献

[1] オートオークションのご案内 — Used car System Solutions: http://www.ussnet.co.jp/auction/ (参照日: 2018/8/1)

[2] DataLine 査定サービス: https://www.proto-g.co.jp/product/corporation/dataline_satei.html (参照日: 2018/9/1)

[3] 田中勝人: 現代時系列分析, 岩波書店, 2006.

[4] Trevor Hasite, et al.: 統計的学習の基礎 －データマイニング・推論・予測－, 共立出版, 2014.

[5] Zhi-Hua Zhou: Ensemble Methods: Foundations and Algorithms, Chapman and Hall/CRC, 2012.

[6] 西垣通, 集合知とは何か, 中公新書, 2013.

[7] Xavier Glorot and Yoshua Bengio: “Understanding the difficulty of training deep feedforward neural networks,” Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics, pp.249–256, 2010.

[8] Kaiming He, et al.: “Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification,” Proceedings of the 2015 IEEE International Conference on Computer Vision (ICCV), pp.1026–1034, 2015.

[9] Yoshua Bengio, Pascal Lamblin, Dan Popovici, and Hugo Larochelle: “Greedy layer-wise training of deep networks,” Advances in Neural Information Processing Systems, vol.19, p.153, MITPress, 2007.

[10] Diederik P. Kingma and Jimmy Ba: “Adam: A Method for Stochastic Optimization,” arXiv preprint arXiv:1412.6980, 2015.

ビジネスイノベーションのケースを記述する形式モデル

A Formal Description Model for Business Innovation Case

國上真章 [1]　菊地剛正 [2]　寺野隆雄 [3]

Masaaki Kunigami [1], Takamasa Kikuchi [2], and Takao Terano [3]

[1] 東京工業大学
[1] Tokyo Institute of Technology
[2] 慶應義塾大学
[2] Keio University
[3] 千葉商科大学
[3] Chiba University of Commerce

Abstract: We propose a formal model for describing managerial decision processes in cases of business innovation. This formal model named Managerial Decision-making Description Model (MDDM) consists of three kinds of components, an environment, a business structure and an agent's decision. The business innovation is represented as a business structure transition, in which the agents redefine the objective-resources pairs in the business structure. We show that the MDDM describes actual business cases and compares their similarities and differences. We also consider the MDDM application to case based analysis on organizational simulation and business gaming.

1　はじめに

本稿は，ビジネスイノベーションのケースにおける意志決定を形式的に記述する経営意志決定記述モデル（Managerial Decision-making Description Model, 以下 MDDM）[1][2]を提案する．ここで，ビジネスイノベーションとは，組織のビジネス構造の変化を伴う経営意思決定がなされていることを示す．MDDM はビジネスケースにおける, 組織の置かれた環境と組織内の意思決定主体（以下 エージェント）による経営意思決定を形式的に記述することで，ビジネスイノベーションのケースを相互に比較可能とすることができる. また, ビジネスケースと同様に, シミュレーションおよびビジネス・ゲーミングにおける意志決定プロセスを視覚化する共通の方法を提供する．

ここで，本稿では,「組織のビジネス構造」,「ビジネス構造の変化を伴う経営意思決定」を以下の意味で用いる．組織のビジネス構造とは，組織のトップマネジメントから現場までの各階層における目的, 目標とそれを実現するために必要な資源，手段の組合せ（以下，目的 - 手段結合（Objective-Means Coupling））の階層構造の意味で，またビジネスの構造の変化を伴う経営意思決定とは，各階層のエージェントが，その階層における目的 - 手段結合を再定義すること，この結果としてビジネス構造が変化することの意味で用いる．

MDDM は，OMG（Object Modeling Group）の Case Management Model and Notation [3]等の記述言語が定常的なビジネスプロセスの内部の詳細な記述[4][5]を指向するのに対し，目的 - 手段結合によって表現されたビジネス構造とビジネス構造そのもの一回限りの変化とそれを引き起こす経営意思決定に焦点を当てる点で異なり，このためビジネスイノベーションのケースを可視化することに適する．また，サービス・サイエンスにおけるハイレベル・ビジネスケース（HLBC）[6]が，ビジネス構造のイノベーションを，ビジネス構造の機能・サービスの内容の変化から記述するのに対し, MDDM はビジネス構造の変化を，変化を駆動するエージェントの意思決定に注目して記述する．

MDDM は, ビジネスイノベーションにおける経営意思決定を，以下の要件を含む決定図式（Decision Diagram）として記述する．

a）ビジネス構造の階層性とその変化
b）エージェントの観察・行動の対象の範囲と限界
c）ビジネス構造に対するエージェントの位置づけ
d）エージェントの意思決定の順序，因果関係

これらにより, MDDMの決定図式は, 誰が(who), 何時（when)，組織の何処で（where)，何を（what) 意思決定し, その結果, ビジネスがどのように(how) 変化したのかが記述可能となる.

2 提案方法

経営意志決定記述モデル MDDM は，環境（Environment)，ビジネス構造（Business Structure) エージェントの意思決定（Agent's Decision） という３種類のコンポーネントからなる．MDDM は，これらを互いに結線することにより，ビジネスケースを決定図式として記述する.

2.1 ビジネス構造（Business Structure）

ビジネス構造（Business Structure）コンポーネントは，組織のビジネスを，目的 - 手段結合（Objective-Means Coupling）の階層的な構造として表現する．ビジネスの階層は，上層（例えば，トップマネジメント，戦略レベル等）から下層（チームマネジメント，現場レベル等）等，ビジネスの性質と記述の粒度に応じて適切に区分する.

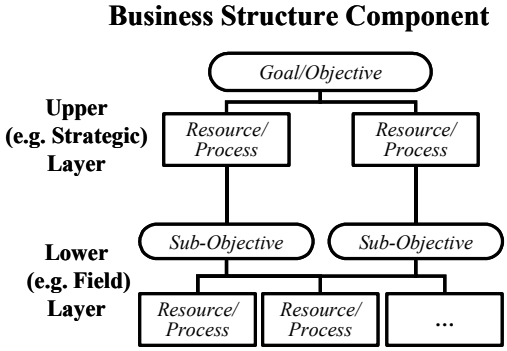

図１：ビジネス構造コンポーネントは，ビジネスにおける目的 - 手段結合の階層構造を表わす.

ビジネス構造コンポーネント（図１）は，目的シンボル（Objective Symbol)，手段シンボル（Resource Symbol）およびそれらの接続子（Connection）からなる．目的シンボルはビジネス構造の該当する階層における目的（Goal）あるいは目標（Objectives）を表わす．資源シンボルは，接続子によって連結された目的シンボルを達成するために必要な手段（Means）としての資源（Resources)，プロセス（Process)を表わす． ビジネス全体の階層構造は，上層の手段シンボルが，下層の対応する目標シンボルと接続され具体化することにより表現される.

2.2 環境（Environment）

環境（Environment）コンポーネントは，状態シンボル（State Symbol）およびイベントシンボル（Event Symbol）および接続子（Connection）からなる．状態シンボルは，技術，市場，制度，他組織の動向等，外部条件それらの変化，あるいは財務，人事，部内技術等の内部条件とそれらの変化を表わす．イベントシンボルは，特定の状態あるいはその変化がエージェントの決定を引き起こすという出来事，あるいはエージェントの決定が状態の変化を引き起こすという出来事を示す.（図２）

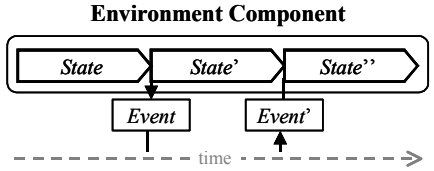

図２：環境コンポーネントは，ビジネス内外の状態と状態が引き起こすイベントを表わす.

環境コンポーネントでは，シンボルシンボルが，左から右に生起順に配置し，時間的順序も表わす.

2.3 意思決定（Decision-making）

エージェント意思決定（Decision-making）は，エージェントが組織のビジネス構造における特定の目的 - 手段結合を変更・再定義することとして表現する．エージェントの個々の意思決定は，４つの端子（terminal）を備えた意思決定素子（Decision-making Element）として表す．また意思決定素子は，接続子（Connection）によりイベントシンボル（Event Symbol）を介して環境コンポーネントおよび他のエージェントの意思決定素子に結線され，これらの間における因果関係等を表現する.（図３）

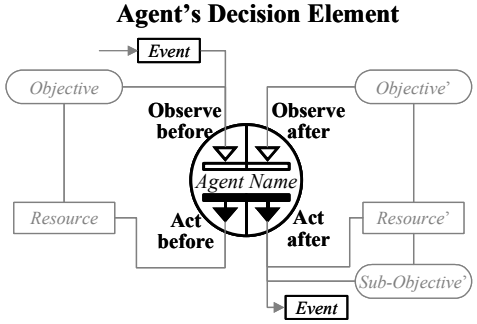

図３：意思決定素子は，エージェントの意思決定を目的 - 手段関係の変化・再定義として表わす.

意思決定素子は，エージェントの名称と左右２組計４つの端子からなる．意思決定素子の左２つの端子はエージェントの意思決定以前における観察 - 行動ペア（observation-action pair）を表わし，右２つの素子は意思決定以前における観察 - 行動ペアを表わす．それぞれの観察 - 行動ペアは，ビジネス構造の

目的シンボルと手段シンボルに接続子により結線される．これにより意思決定するエージェントの，観察 - 行動ペアとそのエージェントにとっての目的 - 手段結合が対応付けられる．

左の観察 - 行動ペアにおいて，左上の端子は，接続子によりエージェントが意思決定以前に目的，目標として観察，参照していたビジネス構造のシンボルに結線される．また左下の端子は，上の目標のための資源あるいは手段として操作，行動の対象としていたビジネスの要素に結線される．

これに対し右の観察 - 行動ペアの右上の端子は，意思決定の結果としてエージェントが新たに目標としたビジネス要素に結線される. また右下の端子は，その新しい目標のための手段として新たに操作，行動の対象とされたビジネスの要素に結線される．

このように意思決定素子は, ビジネス構造のうち，特定の目的 - 手段結合の変更・再定義としてエージェントの経営意思決定を表現することができる．

また，意思決定素子の左上の観察端子は，環境や他のエージェントの意思決定接続されたイベントシンボルと接続子により結線されることで，この意思決定がこれらのイベントがトリガーとなって生起したことを表わす．同様に，意思決定素子の右下の行動端子は，接続子によりイベントシンボルを介して他のエージェントの意思決定や環境と結線され，その意思決定が他のエージェントの意思決定や環境の状態変化のトリガーとなっていることを表わす．

2.4 決定図式（Decision Diagram）

MDDM は，ビジネス構造，環境，意思決定素子という３種のコンポーネントを用いて，ビジネスイノベーションを伴う経営意思決定を決定図式として表現する．決定図式は，３種のコンポーネントを配置し，コンポーネントの各要素を接続子により結線することにより構成される．

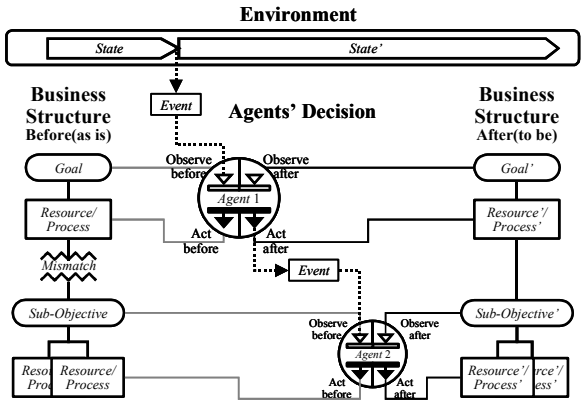

図４：決定図式：３種類のコンポーネントを配置結線し，決定図式（Decision Diagram）としてビジネスケースを記述する

決定図式の構成は，コンポーネントの配置と結線からなる．以下，環境，２つのビジネス構造，エージェントの意思決定について配置の仕方を示す．

はじめに，環境コンポーネントを決定図式の上辺または下辺あるいは必要に応じて両方に配置する．（図４ 上）

次に，ビジネスイノベーション前後の２つのビジネス構造コンポーネントを，決定図式の左右両端に配置する．このとき左側には構造変化以前に存在したビジネス構造を配置し，「Before」構造または「As Is」構造と呼ぶこととする．（図４ 左）

一方，右側にはエージェント達の経営意思決定の結果として新たに再定義された目的 - 手段結合から構成されるビジネス構造を配置し，これを「After」構造または「To Be」構造と呼ぶ．（図４ 右）

これらの左右のビジネス構造コンポーネントと環境コンポーネントは，決定図式内の水平方向に時間順序を与える. また決定図式内の垂直方向の位置に，経営戦略，トップマネジメントから，チームマネジメントにいたる上下関係を導入する．

これらの, 環境コンポーネント, ビジネスの Before と After 構造コンポーネントで囲まれた領域内に，エージェントによる意思決定素子を配置し，これらを接続する．意思決定素子は，意思決定の対象となる目標と資源が属する垂直階層と，意思決定が行われる時間順に対応する水平位置に配置される．

最後に，決定図式内での意思決定素子と，Before と After ビジネス構造コンポーネント，環境コンポーネント，他の意思決定素子を，接続子により必要に応じてイベントを介して結線する．このときの接続ルールは, 2.3 意思決定素子において記したとおりである．

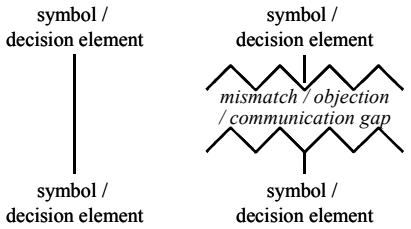

図５：シンボル，意思決定素子間に関係が成立している場合はそれぞれを結線して表わす．（左）一方，あるべき関係が成立していない場合は，断線シンボルを間に置くことで表わす．（右）

一方，本来結線されるべきコンポーネントのシンボルや意思決定素子の間の関係が成立していない場合は，これを明示するために，断線シンボルを用い

る．断線シンボルにより，ビジネス構造内での目的‐手段結合の不成立または上層‐下層間の不整合，あるいは意思決定素子とイベント間におけるエージェント間の意思疎通の不在あるいは意見対立を表現することができる．（図５）

このように構成された決定図式は，セクション１で提示した表現上の要件（a）～（d）に対応していることを示している．

(a) Before After 二つのビジネス構造コンポーネントによって，ビジネス構造の階層構造とその変化の内容を表現できる．

(b) 各エージェントの観察・行動端子とビジネス構造の要素との結合が，エージェントの観察・行動の対象を示し，エージェントの対象・範囲が限定されていることを表わしている．

(c) 各意思決定素子の垂直方向の位置が，エージェントまたはその意思決定が関与するにビジネスの構造の層に対応する．

(d) 各意思決定素子の水平方向の位置が，意思決定決定の時間順序を反映する．また環境の状態と意思決定素子，意思決定素子と意思決定素子間の結線は，それらの間の因果関係を表わす．

2.5 決定図式の拡張（Extension）

ここでは，決定図式を拡張することにより，複数の組織の経営意思決定あるいは競争的なビジネスケースを記述する．これまで述べた MDDM の意思決定図式で記述可能なのは，ひとつの組織の経営意思決定である．しかし，競争的なビジネスケースを記述するためには，複数の経営意思決定が相互作用する過程を表現する必要がある．そこで決定図式を，複数の決定図式が共通のコンポーネントを介して相互に影響しあうように拡張する．

拡張された決定図式（Extended Decision Diagram）（図６）は，複数の決定図式と共通の環境（Common Environment）コンポーネントからなる．共通の環境は，それぞれの決定図式から観測可能な状態とその変化を表わすとともに，それぞれの決定図式からの影響，決定図式への影響を示すイベントを含む．

共通の環境コンポーネントによって，決定図式間の相互作用を記述することによる利点は次のとおりである．一般に，競争環境下においてそれぞれの組織は，相手について限定された情報しか持ち得ないが，共通の環境を介することで，そのような知り得る情報の不完全性を表わすことができる．また共通の環境によって，複数のケース間に大域的な時間順序を導入することができる．

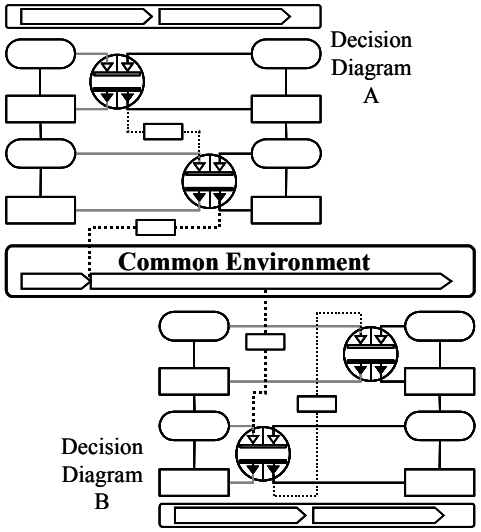

図６：拡張された決定図式（Extended Decision Diagram）では，複数の決定図式が共通の環境（Common Environment）を介して影響しあう．

3 ビジネスケースへの適用

ビジネスイノベーションのケースを, MDDM の決定図式（Decision Diagram）として表現する．基本的な例として，トップダウン型とボトムアップ型の意思決定スタイル，および組織における非公式コミュニケーションの寄与について，実際のビジネスケース決定図式を作成し比較する．これにより MDDM で実際のビジネスケースが形式化できること，特に決定図式によりビジネスケースにおける組織の意思決定を比較できることを示す．

3.1 トップダウンとボトムアップ

経営意思決定スタイルの最も基本的な例としてトップダウン型とボトムアップ型の意思決定の相違を比較する. MDDM によるトップダウン型の経営意思決定の決定図式は，意思決定素子が右下がりの直列接続となる．これに対し，ボトムアップ型の経営意思決定の決定図式は，右上がりの意思決定素子の直列接続となる．（図７）

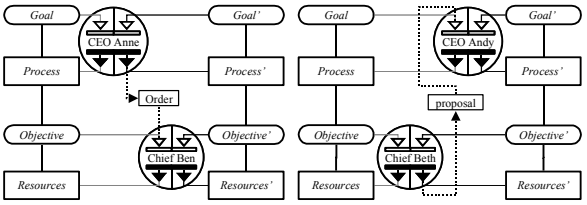

図７：トップダウン型の経営意思決定の決定図式（左）とボトムアップ型の決定図式（右）

実際のイノベーションのケースにおけるボトムアップ型の経営意思決定の古典的な例として，クリステンセンの著作[7]から，ホンダによる北米二輪車市場への進出過程のケースの決定図式を図８に示す．ビジネス構造 Before は，当初ホンダが北米市場で人気のあった Harley Davidson や BMW のような大型高速のハイウェイ・バイク市場に，低コストを武器に参入しようとしていたこと，このためロス・アンゼルスに派遣された川島（アメリカン・ホンダ・モーターズ支配人 当時）等が経費節約のために持ち込んだ Super Cub に乗りながら現地ディーラーの開拓を行っていたことを表わす．環境は，ホンダの大型バイクが北米市場に受け入れられなかったこと，一方，川島等がオフロードで気晴らしに走らせた Super Cub が，消費者の関心と需要を喚起したことを表わす．意思決定素子は，川島が，軽量のリクリエーション・バイクを北米市場に本格投入するよう東京の本社を説得し，本社が戦略を変更したことを表わす．ビジネス構造 After は，ホンダが軽量リクリエーション・バイクにより北米において新たな市場の創造を目指し，スポーツ用品店など新しいディーラーの確保や宣伝活動をしたことを表わす．

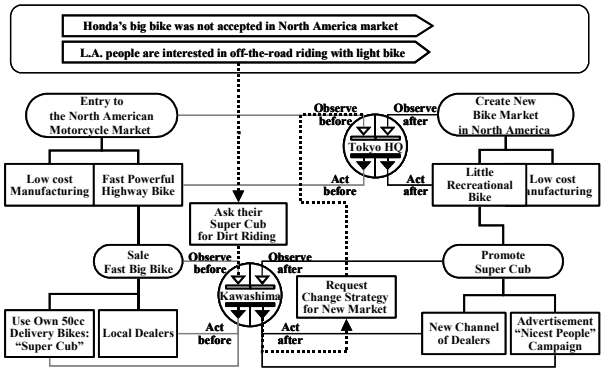

図８：ホンダのケース[7]の決定図式，典型的なボトムアップ型になっている．

ホンダのケースの決定図式（図８）は，右上がりに配置された現地マネージャーである川島と東京本社の意思決定素子を，川島から本社への要請イベントが直列に接続しており，ホンダビジネス構造がボトムアップに変化する過程を表現している．

3.2 非公式コミュニケーション

社内における非公式なコミュニケーションは，経営意思決定においてさまざまな影響を及ぼし得る．MDDM の決定図式では，非公式なコミュニケーションは，エージェント間における組織内での正規の方法や経路によらないイベント，あるいはビジネス構造内に正規の位置づけを持たないエージェントが引き起こすイベントにより表わされる．

ここでは，ソニーの公式サイト[8][9]から，ヘッドホン・ステレオ（ウォークマン）の市場創造についてのケースの，MDDM の決定図式を図９に示す．環境は，ソニーがコンパクトカセットテープの技術を導入後，テープと録音再生機の性能が向上していたことを表わす．ビジネス構造 Before は，ソニーがカセットテープ用録音再生機の製品として，高性能のステレオ録音再生機と，ハンディなモノラル録音再生機を製造していたことを表わす．意思決定素子は，当時名誉会長であった井深の個人的な要望に応じて，テープレコーダー事業部長の大曽根が，ハンディタイプのモノラル録音再生機を改造してステレオ再生専用機を試作したことと，出来上がった試作機を井深が会長である盛田に試用させたことをきっかけに，盛田がこの試作機を製品化し市場に投入する決断をしたことを表わしている．ビジネス構造 After は，ソニーが新たに，ハンディな高音質再生専用機の市場の創造へと指向したこと，この際に事業部の大曽根が，新しい製品コンセプトに対する顧客からの支持を失わないよう，製品の信頼性を重視したことを示している．

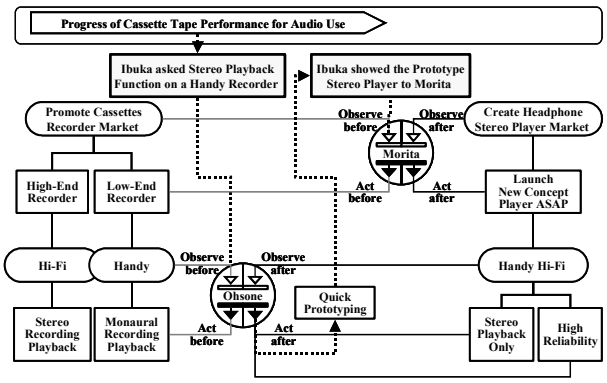

図９：ソニーのケース[8][9]の決定図式，ホンダの決定図式（図８）に類似しているものの，井深の個人的行動よる非公式コミュニケーションの存在が相違点になっている．

ソニーのケースの決定図式は，意思決定素子の配置についてはホンダのケースと同様であるが，意思決定間の結ぶイベントの内容と主体が異なる．ホンダのケースにおいては，北米の川島からの要請というイベントが本社の戦略変更を引き起こしている．これに対し，ソニーのケースでは，事業部の大曽根の行動と会長である盛田の戦略決定が，名誉会長である井深の個人的行動イベントを介して結ばれている．ここで，ソニーのケースとホンダのケースとの差異は，井深の社内におけるトリックスターとも見える非公式なコミュニケーションであることが決定

図式の比較から可視化される．

このように, MDDM によりケースを決定図式で記述することにより，ケース間の類似性，相違点を形式的に比較することが可能となる．

3.3 競争的な２つ組織の意思決定

複数の組織が競合的な環境でビジネスイノベーションを試みるような場合には, 2.5 で示した拡張された決定図式（Extended Decision Diagram）を用いる．拡張された決定図式により，互いの影響下でのそれぞれの組織の経営意思決定を記述することができる．

例としてここでは, 3.1 で触れたホンダの北米市場進出のケース[7]から，ホンダの進出に対抗しようとしたハーレーダヴィッドソンの戦略変更の失敗についての決定図式を図１０に示す．

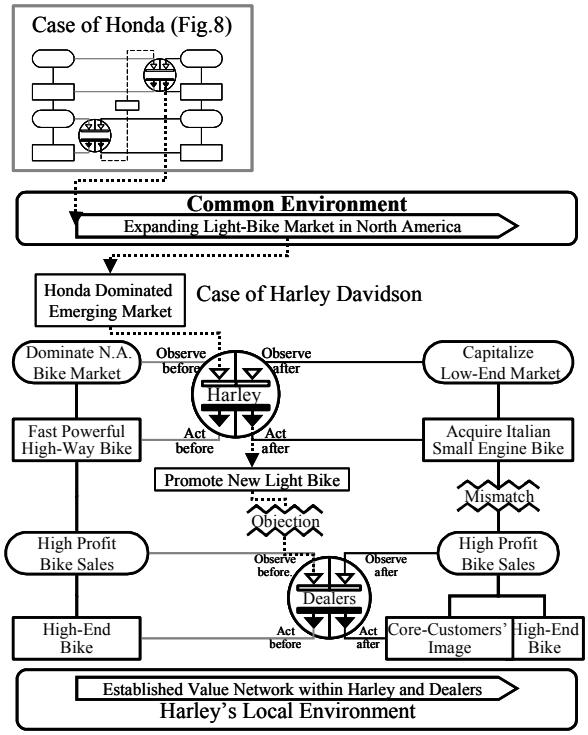

図１０：ホンダの市場進出（左上および図８）と軽量バイク市場の創造（中央の共通環境）に対して挑戦を試みたハーレーの戦略変更の失敗[7]（中央下）についての拡張された決定図式.

図１０において，ホンダが与えた市場への影響は共通環境（Common Environment）を通じてハーレーの意思決定を起動している．ここでハーレーはホンダが創造した軽量バイク市場に挑戦すべく，イタリアのエアロメカニカ社から導入した新型の軽量バイクを，自身の強みである参加のディーラー網を通じて販売しようとした．しかしながら，ハーレーとハーレーの主要顧客との間で高利幅の大型バイクを販売していた（ハーレーのローカル環境）ディーラーは，利幅の少ない小型バイクを販売してコアカスタマーのブランドイメージを損ねることに反対（ハーレーとディーラーの間の断線シンボル）した．この結果生じたハーレーの戦略とディーラーの求めるビジネスとの不整合は，ビジネス構造 after の断線シンボルによって表現されている．

4 考察

MDDM の適用可能性として，エージェント・ベースの組織シミュレーションおよびビジネスゲームへの応用について考察する．なお紙面の制約上，本稿では可能性の考察にとどめ，具体的適用については稿を改めて検討する．

エージェント・ベースの組織シミュレーションにおいても，シミュレーションのログから生成された仮想ケース[10]が利用されている．この仮想ケースは，シミュレーション・モデルの内容がシミュレーションの対象となった現象に接地するのを確認するために用いられている．エージェント・シミュレーション結果が，自然言語で記述された仮想ケースによって現実のケースと比較可能であることから，エージェント・シミュレーションから生成される仮想ケースを, MDDM で表現することで仮想ケースの中の意思決定過程を可視化し形式的に比較することが可能である．これについては本研究会の別稿[11]で報告する．

エージェント・シミュレーションに基づくビジネスゲーム，あるいはビジネスケースに基づくゲーミング[12]についても MDDM の適応可能性があると考えられる．特に後者においては，ゲームデザイナーあるいはファシリテーターのゲームデザインについての解釈の原型を明確にするために，またプレーヤーのゲーム内容についての理解とプレーヤー間での差異を把握するために, MDDM を活用する事が考えられる．

5 まとめ

本稿では，ビジネスイノベーションのケースを形式的に記述するモデルとして MDDM（Managerial Decision-making Description Model）を提案した．MDDM により, 組織のビジネス構造の変化を伴う経営意思決定を，決定図式（Decision Diagram）として記述する．決定図式は，ビジネス構造とその変化，意思決定を行うエージェントの限定された観察と行動の変化，エージェントのビジネス構造の中での位置づけ，エージェントの意思決定の時間的順序や因果関係を形式化して表現することができる．また拡張された決定図式（Extended Decision Diagram）は，

競争的な状況における複数の組織の経営意思決定を形式的に表現することができる.

MDDM の適用について, ケース間の意思決定スタイルの類似性と相違を比較することができることを, ホンダとソニーの実際のケースを用いて示した.

また，今後の適用可能性として，エージェント・ベースの組織シミュレーションあるいは，ケースベースのビジネスゲームへの適用可能性について考察した.

参考文献

[１] Kunigami, M., Kikuchi, T., Terano, T.: A Formal Model of Managerial Decision Making for Business Case Description, GEAR2018: Letters of the Special Discussion on Evolutionary Computation and Artificial Intelligence, (2018).

[２] 國上真章, 菊地剛正, 寺野隆雄: ビジネスケースの経営意思決定を記述するための形式モデル ,合同エージェントワークショップ＆シンポジウム 2018 (JAWS2018)予稿集,(2018).

[３] Object Management Group: The Case Management Model and Notation Specification (CMMN) Ver.1.1, https://www.omg.org/spec/CMMN/, (2016).

[４] Object Management Group: The Business Process Model and Notation Specification ver.2.0.2, https://www.omg.org/spec/BPMN/, (2014).

[５] Object Management Group: The Decision Model and Notation Specification Ver.1.2, https://www.omg.org/spec/DMN, (2016).

[６] Sawatani, Y., Kashino, T., Goto, M.: Analysis and Findings on Innovation Creation Methodologies, https://www.slideshare.net/YurikoSawatani/analysis-and-findings-oninnovation-creation-methodologies, slide 15, last accessed 2018/06/23, (2016).

[７] Christensen, C. M.: The Innovator's Dilemma: When New Technologies Cause Great Firms to Fail, Harvard Business Review Press, pp.149-153, (1997 reprint 2016)

[８] Sony Official Website: Sony History, Chapter 5 Prompting Compact Cassettes Worldwide, https://www.sony.net/SonyInfo/CorporateInfo/History/SonyHistory/2-05.html, last accessed 2018/05/20.

[９] Sony Official Website: Sony History, Chapter 6 Just Try It, https://www.sony.net/SonyInfo/CorporateInfo/History/SonyHistory/2-06.html, last accessed 2018/05/20.

[１０] Kobayashi, T., Takahashi, S., Kunigami, M., Yoshikawa, A., Terano, T.: Is There Innovation or Deviation? Analyzing Emergent Organizational Behaviors through an Agent Based Model and a Case Design. In: Proceedings on The 5th International Conference on Information, Process, and Knowledge Management (eKNOW 2013), pp.166-171 (2013).

[１１] 菊地剛正, 國上真章, 高橋大志, 鳥山正博, 寺野隆雄:ビジネスケースとエージェントモデルのシミュレーション･ログの統一的な記述モデル, 人工知能学会研究会, 10th SIG-BI, (2018).

[１２] Nakano, K., Matsuyama, S., Terano, T.: Research on a Learning System toward Integration of Case Method and Business Gaming. In: Proceedings on The 4th International Workshop on Agent-based Approach in Economic and Social Complex Systems (AESCS 2007), pp.21-32 (2007).

ビジネスケースとエージェントモデルのシミュレーション・ログの統一的な記述モデル

A Formal Description Model for Buniness Case and Simulaiton Log from Agent-based Model

菊地 剛正 [1]　國上 真章 [2]　高橋 大志 [1]　鳥山 正博 [3]　寺野 隆雄 [4]

Takamasa Kikuchi[1], Masaaki Kunigami[2], Hiroshi Takahashi[1], Masahiro Toriyama[3], and Takao Terano[4]

[1] 慶應義塾大学 [2] 東京工業大学 [3] 立命館大学 [4] 千葉商科大学

[1]Keio University [2]Tokyo Institute of Technology [3]Ritsumeikan University [4]Chiba University of Commerce

Abstract: 組織におけるビジネス構造の転換を伴う経営意思決定を形式的かつ比較可能に表現するモデルとして，「経営意思決定記述モデル」(MDDM)が提案されている．当該モデルは，実際のビジネスケースやエージェントモデルのシミュレーション･ログを一定の共通形式で表現できる可能性が指摘されている．本稿では，企業組織の外部環境に対する認識の伝播を扱った実際のビジネスケースを MDDM を用いて記述した．更に，エージェント・ベースの組織シミュレーションモデルを構築し，シミュレーション・ログから生成された仮想ケースを同様に記述した．その上で，リアルなケースとバーチャルなケースの双方が相互比較可能であることを示した．

Keywords: agent-based simulation, business case, decision making, business structure

1. はじめに

社会的・組織的な現象や問題を理解し，システムのデザインへ繋げるための手法として，エージェントモデル（以下，”ABM”とする）とケーススタディを接地させるアプローチが提唱されている[1]．例えば，小林ら[2]は，企業組織の改善行動と逸脱行動は既定の規範から逸れるという点で同様の作動原理であるとの仮説のもと，ABM を構築している．シミュレーション結果から仮想的なケース（以下,「仮想ケースとする」）を生成し，実際のビジネスケース（以下,「実ケース」とする）との接地を図っている．但し，ケース間の比較・検証を行う際の概観性については改善の余地がある．

一方，ビジネス構造の転換を伴う経営意思決定を形式的かつ比較可能に表現するモデルとして,「経営意思決定記述モデル」(MDDM)が提案されている[3]．当該モデルは，ビジネスケースやエージェントモデルのシミュレーション・ログを一定の共通形式で表現できる可能性が指摘されている．

本稿では，企業組織の外部環境に対する認識の伝播を扱ったビジネスケース[4]を MDDM を用いて記述する．更に，エージェント・ベースの組織シミュレーションモデルを構築し，仮想ケースを同様に記述した．その上で，実ケースと仮想ケースの双方が概観性をもって比較可能であることを示す．

2. 関連研究

2.1 MDDM

ビジネスケースにおける組織のビジネス構造の変化を扱うエージェントの意思決定を形式的かつ比較可能に表現するモデルとして,「経営意思決定表現モデル」(MDDM)が提案されている[3]．このモデルは，ビジネス構造，環境，エージェントの意思決定という 3 種類の要素からなる．これらの要素をフレーム内に配置し互いの関係に応じて結線することで，組織のビジネス構造の変化を伴う意思決定を，「決定図式」として記述する．

ここで，「ビジネス構造」コンポーネントは，組織の各階層(Strategic Layer, Middle Layer, Field Layer 等)における「目的」シンボルと「資源」シンボルか

らなる.「環境」コンポーネントは，組織内外の「状態」シンボルとその変化からなり， 時間の推移に沿って配置される．また状態の変化が生成する「イベント」シンボルも配置される．

エージェントの「意思決定」コンポーネントは，4 つの端子を持つ素子で表す．上の 2 端子には，エージェントが観測する対象を，下の 2 端子には，エージェントが行動する対象を接続する．

このモデルは，以下の 4 要件を記述可能である：

a) 組織におけるビジネス構造の階層性とその変化.
b)ビジネス構造の階層におけるエージェントの位置づけ.
c) エージェントの認知・作用対象の範囲・限界.
d) エージェントの意思決定の時間的位置，順序関係.

当該モデルは，実際のビジネスケースやエージェントモデルのシミュレーション・ログを一定の共通形式で表現できる可能性が指摘されている．

以下，経営意思決定によるイノベーションの古典的な事例として，ホンダによる北米二輪車市場への進出過程のケース[4]を MDDM により記述する．本ケースの概要は以下の通りである：

・当初ホンダは，ライバル同様，大型高速のハイウェイ・バイク市場を攻略すべく目的・目標を設定していたが，営業成績が振るわなかった．
・現地マーケティング統括の川島氏は，現地民とのコミュニケーションから，小型・レクリエーション用のバイク市場が存在することを認知．東京本社に訴え，全社的な戦略を変更することに成功した．
・当該戦略転換が奏功し，北米ローエンド・バイク市場を攻略．更に上位市場へ進出する戦略を採り，遂には欧米のバイク市場で確固たる地位を築いた．

当該ケースは，ボトムアップ型の意思決定が行われたケースであることが見て取れる(図 1).

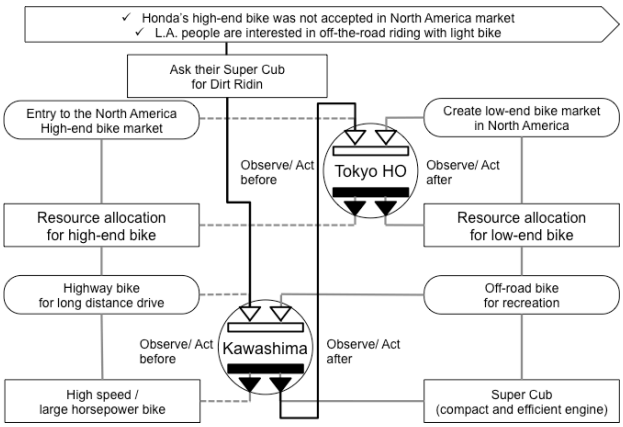

図 1 MDDM を用いてホンダの北米二輪車市場への進出のケース[4]を記述した例．Field Layer から Strategic Layer を経由した意思決定が行われており，ボトムアップ型の意思決定が行われたケースであることが見て取れる．

2.2 ビジネスケースと ABM の接地

小林ら[2]は，組織の逸脱と改善にかかる ABM を構築し，ABM のシミュレーション・ログから生成した仮想ケースと実ケースのシナリオ・ストーリーの接地を図った．具体的には，実ケースから作成したケースの骨格を表す「テンプレート」を用いて，シミュレーション・ログを仮想ケースとして自然言語により記述し，実ケースとの比較を行った．結果として，仮想ケースと実ケースは比較可能であることを示した．但し，ケース間の比較は自然言語ベースで行われているため，1) 記述レベルをコントロールすることが難しい点，2) シミュレーション・ログを書き下す作業が煩雑である点，などについては改善の余地がある．

また，國上らは，MDDM を用いて，小林ら[2]の仮想ケースを書き下した[3] (図 2). MDDM は自然言語に比べ，抽象的な記述言語であり，概観性をもった形でケースを記述できる可能性がある．

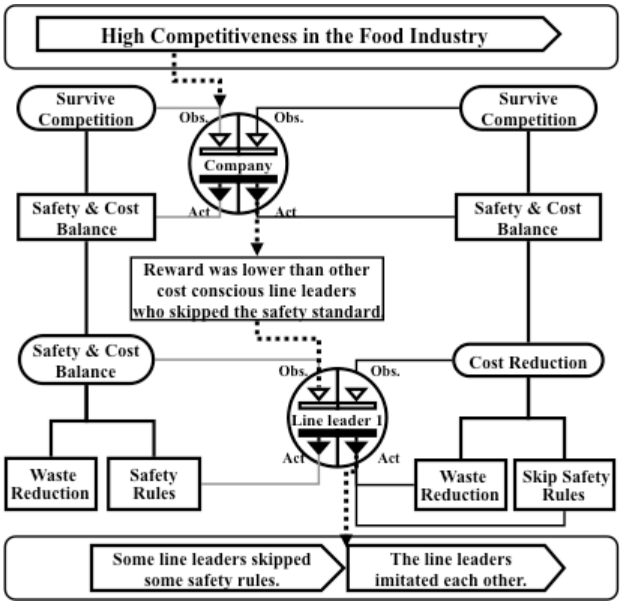

図 2　ABM のシミュレーション結果から記述された仮想ケース[2]の一部を MDDM を用いて書き下した例[3]. 当該 ABM は，食品業界の製品製造現場でのコスト削減と安全性のトレードオフの問題に注目．上記ケースは，過当競争の下，現場ではライン間で原価低減を最優先とするような模倣学習が行われ，結果として安全性が軽視されてしまったものであり，企業組織の逸脱行動を表現している．

本稿では，これらの成果を参照し，ABM のシミュレーション・ログを MDDM により直接書き下す．自然言語を介さず，統一性を持った形で実ケースと仮想ケースが比較可能であることを示す．

3. モデル

3.1 概要

本稿では，「組織の環境認識モデル」[5]を参照して ABM を構築する．当該モデルは，Axelrod のタグモデル（文化の流布モデル）[6]を元に，組織構成員の外部環境の認識伝播を表現したモデルである．拡張の方向性は，エージェントの性質と空間構造の 2 つである : 1) 通常のタグモデルでは考慮されていなかった，各エージェント固有の性質として，認知バイアスや，環境変化を認知するエージェントであるか否か，を表現すること．2) 各エージェントは，セル状の空間構造ではなく，コミュニケーション・ネットワークによって繋がりを持つこと．

3.2 エージェント

3.2.1 構成員とその属性

本稿で扱う組織は, N 人の構成員からなるとする．

$$Or = \{a\ ;\ i = 1, \dots, N\}$$

更に, 各構成員が持つ目的及び手段をタグモデルにより表す(図 3). 構成員 a_i が持つ目的の集合 Obj_i は,

$$Obj_i = (obj_{i1}, obj_{i2}, \dots, obj_{im}),\ obj_{ik} \in \{1, 2, \dots, l\}$$

a_i が持つ手段の集合 Res_i は,

$$Res_i = (res_{i1}, res_{i2}, \dots, res_{im}),\ res_{ik} \in \{1, 2, \dots, l\}$$

である（m: 要素数，l: 代替特性）．但し,

$$\dim Obj_i = \dim Res_i = m$$

とする．提案モデルは，MDDM における目的シンボル, そのために必要な手段シンボルを数字列として抽象的に表現したものである．ここで，目的 Obj_i と手段 Res_i の組みをビジネス構造 Str_i とする：

$$Str_i = (Obj_i, Res_i)$$

また，ビジネス構造の要素 str_{ik} は，その構造を保持している時間

$$t_{ik} \in T_i,\ T_i = \{t_g\ ;\ g = 1, \dots, 2m\}$$

を持つ．ここでシミュレーション 1step あたりの保持期間の増分は，$\Delta t_{ik} = 1/100$ とする．

図 3　構成員の目的・手段と外部環境のモデル化.

3.2.2 環境認識主体

構成員のうち，環境変化を認識するものを「環境認識主体」とする．そして，このような構成員の属する階層が 1) 上層（トップ），2) 中間層（ミドル），3) 下層（ボトム），それぞれに偏在しているケースを考える．このように考えるのは，例えば，組織の上層が環境の変化を認識し，その認識を構成員に共有させようとする場合と，下層がそうしようとする場合とでは，認識が伝播される際に要求される組織の諸条件が異なると考えられるためである．

3.3 外部環境

本稿では，構成員の目的・手段と同様，外部環境をタグモデルで表現する(図 3)．外部環境 Env は,

$$Env = (e_1, e_2, \dots, e_{2m}),\ e_k \in \{1, 2, \dots, l\}$$

である．但し,

$$\dim Env = 2m$$

とする．なお，Env は当初の外部環境を表す Env_before と変化後の環境を表す Env_after を持つ．

3.4 ネットワーク

3.4.1 構成員間のネットワーク

タグモデルでは，エージェントをセル状の空間構造に配置し，近接サイト間でのみ相互作用を行なっていた．提案モデルは，ある構成員 a_i とその構成員が持つ C_i^{formal} と $C_i^{informal}$ から選択された構成員

$$a_j \in C_i^{formal} \cup C_i^{informal}$$

の間で相互作用が行われるものとする(3.5.1 節で詳述)．ここで，C_i^{formal} は構成員 a_i が公式コミュニケーション・ネットワークで繋がる構成員の集合であり，$C_i^{informal}$ は非公式コミュニケーション・ネットワークで繋がる構成員の集合である．なお，公式コミュニケーションと非公式コミュニケーションにおいて，認識の伝播のしやすさには差異はないものとする．

3.4.2 外部環境−環境認識主体間ネットワーク

外部環境と環境認識主体の間で相互作用が行われるものとする(3.5.2 節で詳述).

3.5 相互作用

3.5.1 構成員間の相互作用

構成員 a_i と a_j のビジネス構造の近さは，数字列のハミング距離で表し，数字列の中の一致した割合 r_{ij}

$$r_{ij} = \frac{\sum_{k=1}^{2m} \alpha_{ijk}}{2m},\quad \alpha_{ijk} = \begin{cases} 1(str_{ik} = str_{jk}) \\ 0(otherwise) \end{cases}$$

（以下，類似度という）に応じて相互作用をおこす．2 人のビジネス構造が近いほど相互作用がおき易く，相互作用をすればするほど，よりビジネス構造が近くなるモデルである．ここで相互作用とは，a_i と a_j の間で，$str_{ik} \neq str_{jk}$ のとき，(i) str_{ik} を str_{jk} によ

って，または，(ii) str_{jk} を str_{ik} によって，置き換えることをいう．(i)と(ii)のどちらの置換がなされるかは，a_i と a_j の組織構造上の上司・部下関係を判定した上で，後述の「認知バイアス」と「上意下達の割合」を勘案して決定される．

(a) 認知バイアス

タグモデルでは，前述の類似度に応じた確率でタグの要素が書き換わり，文化の伝播を表現していた．

提案モデルでは，構成員が長期にわたってもっているビジネス構造は変わりづらく，また，組織も「環境認識の変わりづらさ」[7][8]を持つという前提から，構成員間のビジネス構造の伝播確率を以下のように定義する．構成員 a_i が持つビジネス構造 str_{ik} を構成員 a_j が持つビジネス構造 str_{jk} に伝播させる確率を p_{ijk}，類似度を r_{ij}, str_{jk} を保持している期間を $t_{jk} \in T_j$ とすると，

$$p_{ijk} = r_{ij} \frac{K}{1+(K/p_0-1)e^{-v_{in}t_{jk}}}$$

なる関数を作業仮説として提示する．ここで，感度パラメタ v_{in} を「慣性」とし（$v_{in} \in I$, $I=\{i; 0<i<1\}$），$p_0 = K = const.$ とする．

(b) 上意下達の割合

相互作用を行う2人の構成員 a_i と a_j が決定した後，a_i と a_j の上司・部下関係（4.2.1 節で示す構成員のナンバー）が参照される．そして，認識の伝播の方向が次のように決定される：1)上司から部下へ，確率 r_{td}，2)部下から上司へ，確率 1-r_{td}．ここで，確率 r_{td} を「上意下達の割合」とする．

3.5.2 外部環境-環境認識主体間の相互作用

提案モデルでは，組織の側から外部環境を操作することは考えない．すなわち，外部環境は環境認識主体と相互作用を行うことで認識を伝播させるが，その逆は取り扱わないこととする．

ここで，外部環境 E の k 番目の要素を構成員 a_i に伝播させる確率 p_{iEk} は，

$$p_{iEk} = r_{iE} = \frac{\sum_{k=1}^{2m} \beta_{iEk}}{2m}, \quad \beta_{iEk} = \begin{cases} 1(str_{ik} = e_k) \\ 0(otherwise) \end{cases}$$

で与えることとする．

3.6 パフォーマンス

組織のパフォーマンスを以下のように定義する．

$$performance = \frac{1}{N}\frac{1}{2m}\sum_{i=1}^{N}\sum_{k=1}^{2m}\gamma_{ik}$$

$$\gamma_{ik} = \begin{cases} 1(str_{ik} = e_k) \\ 0(otherwise) \end{cases}$$

この定義から，シミュレーション時間全体において，構成員間での認識の一致度合いが高く，外部環境と組織の認識の一致度合いが高いほど，パフォーマンスが高くなるようになっている．なお，後述のシミュレーションでは，組織の階層（トップ，ミドル，ボトム）毎に当該計数を算出する．

4. デモンストレーション

4.1 パラメタ及びシミュレーション設定

3 章で説明したモデルを用い，下表のパラメタによりシミュレーションを行った(表 1).

表 1　本稿のシミュレーションで用いたパラメタセット．

パラメタ名	(a) トップダウン型	(b) ボトムアップ型
エージェント数 N	15	同左
目的・手段集合の要素数 m	3	同左
代替特性 l	2	同左
慣性 v_{in}	0.001	同左
認識伝播に係る定数 p_0	1.0	同左
認識伝播に係る定数 K	0.05	同左
上意下達の割合 r_{td}	60%	同左
組織階層	4	同左
環境認識主体	トップ, 3エージェント (agent#01, #02, #03)	ボトム, 3エージェント (agent#08, #10, #12)
非公式ネットワーク	なし	環境認識主体-トップ間 (トップ: agent#01)

ここで，エージェント数 N：15，組織階層：4（トップ：上位 2 階層，ミドル：第 3 階層，ボトム：第 4 階層），目的・手段集合の要素数 m：3，上意下達の割合 rtd：60%，とした．さらに，ボトムアップ型の意思決定プロセスを表現するために，環境認識主体はボトムの3エージェント(agent#08, #10, #12)とし，それぞれトップ(agent#01)と非公式ネットワークで繋がる設定とした（図 4）．

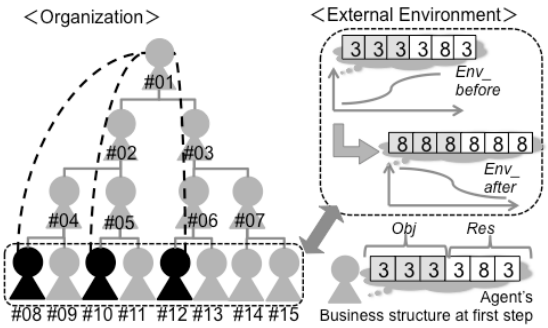

図 4 組織階層の模式図及びシミュレーション設定：ボトムアップ型の意思決定プロセス

4.2 シミュレーション結果

サンプルシミュレーションの結果を示す．下図は組織階層毎のパフォーマンスの推移である(図 5).

初期ステップでは，環境認識主体であるボトムの構成員を通じて外部環境が組織内に伝播していく（例えば，agent#08 のビジネス構造が最初に外部環境と完全一致するのは 13step）．そのため，20step 程度まではボトムのパフォーマンスが先行して向上している．その後，環境認識主体（agent#08, #10, #12）とトップ(agent#01)の間の非公式コミュニケーション・ネットワークを通じ，外部環境がトップに伝播する（agent#01 のビジネス構造が最初に外部環境と完全一致するのは 45step）．更にトップからミドル，ボトムへ上意下達によりビジネス構造が共有されていく(主に 50step 以降)．最終的には，88step にて，全構成員のビジネス構造が新たな外部環境と一致した．

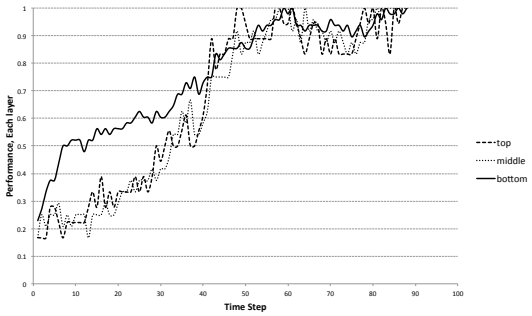

図 5　ボトムアップ型の意思決定プロセスにおける組織階層毎のパフォーマンスの推移.

4.3 MDDM による書き下し

シミュレーション結果を MDDM により書き下したものが下図である(図 6).

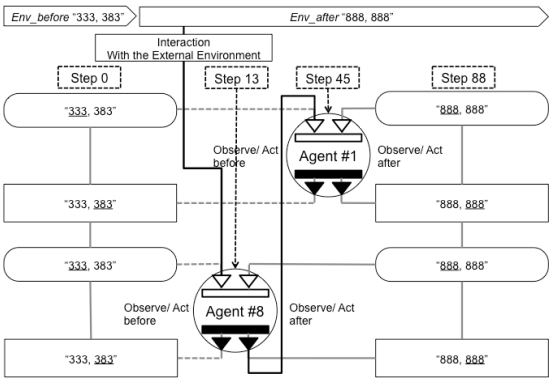

図 6　MDDM を用いて組織の環境認識モデル[5]のシミュレーション・ログを書き下した例．2.1 節で示したホンダのケースの書き下し例と同様, ボトムアップ型の意思決定が行われたケースであることが見て取れる.

ここでは，環境認識主体である agent#08 とトップを構成する agent#01 に注目し, 決定図式を記述した．4.1.2 節で示したホンダのケースと同様，1)ボトムが新たな外部環境を認識し，2)トップを通じて全社のビジネス構造を一様化させた，ボトムアップ型の意思決定が行われたケースであることが見て取れる.

5. さいごに

本稿では，ビジネス構造の変化を伴う組織構成員の意思決定を表現する MDDM を用い，ビジネスケースと ABM において，生成されたストーリーやシナリオが一定の形式で表現可能か検証を行った．具体的には，1) 企業組織の外部環境に対する認識及びその階層間伝播を扱ったビジネスケースのストーリ[4]と，2) 先行研究[5]を元に構築した同様の主題を持つ ABM のシミュレーション・ログ，を書き下すことにより，両者が統一的な形式にて，対比可能であることを確認した(図 1 ; 図 6)．このように，リアルなケースとバーチャルなケースは，一定の概観性をもって相互比較可能である.

今後の課題は以下の通りである : 1) 他のビジネスケースや ABM においても本稿と同様に適用可能であるか検証を行うこと, 2) 本稿はビジネスケースと ABM を対象としたが, 今後はゲーミングをも含めた手法間におけるストーリーやシナリオの共有可能性を探ること.

参考文献

[1] 寺野隆雄，小山友介: “ゲーミフィケーション:世界をゲームとしてデザインする，” *計測と制御*，Vol.54, No.7, pp.494-500, 2015.

[2] 小林知巳，高橋 聡，國上真章，吉川厚，寺野隆雄: “エージェントシミュレーションでケースを説明する，” Proc. JAWS 2012, 2012.

[3] 國上真章，菊地剛正，寺野隆雄: “ビジネスケースの経営意思決定を記述するための形式モデル,” Proc. JAWS 2018, 2018.

[4] Christensen, C., M.: “The Innovator's Dilemma: When New Technologies Cause Great Firms to Fail,” Harvard Business School Press, 1997.

[5] 鳥山正博，菊地剛正，山田隆志，寺野隆雄: “エージェントシミュレーションを用いた組織構造最適化の研究 -スキーマ認識モデル-,” *電子情報通信学会誌*, Vol.J92-D, No.11, pp.1919-1926, 2009.

[6] Axelrod, R.: “The Dissemination of Culture: A Model with Local Convergence and Global Polarization, “ *Journal of Conflict Resolution*, Vol.41, pp.203-326, 1997.

[7] 加護野忠男: “組織認識論,” 千倉書房，1988.

[8] 沼上幹，軽部大，加藤俊彦，田中一弘，島本実: “組織の＜重さ＞,” 日本経済新聞社，2007.

中国株式市場に関する株式価格情報を用いた金融極性辞書の作成

Building a Financial Polarity Dictionary for News Analytics Using Stock Price Information on Chinese Stock Markets

瞿雪吟 [1]　菅愛子 [1]　高橋大志 [1]

Xueyin Qu[1], Aiko Suge[1], and Hiroshi Takahashi[1]

[1] 慶應義塾大学大学院経営管理研究科

[1]Graduate School of Business Administration, Keio University

Abstract: The paper proposes a method of building a sentiment dictionary using news and stock prices in China markets by textual analysis in finance. In order to obtain the amount of word polarities, we associated the frequencies of the news' one-hot wordlist to the abnormal change rate of stock prices on the publish date which is calculated by the method of the event study. We conducted the support vector regression (SVR) and build a sentiment dictionary with polarity data from learners. Furthermore, we attempt to predict the news polarities by using the sentiment dictionary.

1.　はじめに

近年、新聞の紙面やインターネット上には、株式に関連したニュースが多く存在しており、自然言語処理を通じ、資産価格変動とニュースの関連性を明らかにする多くの実証研究がなされている。

例えば、Tetlock［1］は、文章の評価に心理学をベースとした辞書を用い、内容分析を行っている。また、Loughran/ McDonald［2］は、金融分野のテキスト分析のための辞書の提案を行っている。

本研究では、中国株式市場の日次データ、及びニュースデータを用い、中国語の極性辞書の構築を試みる。具体的には、中国本土の上海市場Ａ株と深セン市場Ａ株を対象とし、ニュースから現れた銘柄の株式価格変動から単語のポジティブ／ネガティブの程度（極性）を算出することを試みる。

2.　関連研究

極性辞書に関する分析は数多いが、そのうち金融分野に特化した報告として、五島/高橋［3］が挙げられる。当研究では、ニュースと株式価格のデータから、キーワードリストの作成を行っており、作成した金融辞書により、将来のニュース記事や、異なるメディアのニュース記事の分類を行っている。

また、関/柴本［4］は、個別銘柄の株価など対象とする金融指標によって異なる可能性があるため、金融指標の短期変動に関する語を収録した辞書を作成している。

3.　データ

本研究においてワードリストを作成するため，ニュースは、中国金融情報サイト「和讯首页」[1]で掲載している 2013 年 1 月から 4 月のニュース（合計 6,590 個、関連銘柄数 14,401 個）を使用した。図 1 が示す通り、記事で言及された銘柄は、後ろに証券コードが付与されている。つまり、ニュースと関連する主要銘柄の情報はニュースに含まれている。

这部分个股中，涨幅最多前7只股票均为重组股或借壳股，其中多只个是因停牌早于上证综指攀升至6124高点，意味着这些股票或多或少的缺席了2007年的大牛市，重组后麻雀变凤凰，加之正常补涨，涨幅惊人，如三安光电(600703,股吧)（600703）、广弘控股(000529,股吧)（000529）、中福实业(000592,股吧)（000592）棱光实业(600629,股吧)（600629）等。

図 1　　「和讯首页」掲載新聞の一例

それらに加え、「和讯首页」より「ニュース記事の配信日付時間」、「ニュースの見出し」を抽出した。

ワードの極性評価を行うために、各銘柄の株式リターンとリスクファクター・リターンのデータを用いた。各銘柄の株式リターンとして、ファイナンシャルデータオンラインサービスシステム「同花順」から、株式価格に関する日次データを取得した。また、リスクファクター・リターンのデータは、中国

[1] 和讯首页;http://stock.hexun.com/stocknews/index.html

中央財経大学[2]が提供しているデータを用いた。

4. 作成方法

本研究における、学習用データセットの作成は、大きく二つの部分に分かれる。作成過程の概略を、図 2 に示す。

(1) 教師スコアの算出

はじめに、ニュース配信時間の調整を行った。本分析では、中国証券取引場の営業時間に合わせて、15 時以降に配信されたニュースをその翌日に調整し、また週末に配信したニュースはその次の月曜日に調整した。

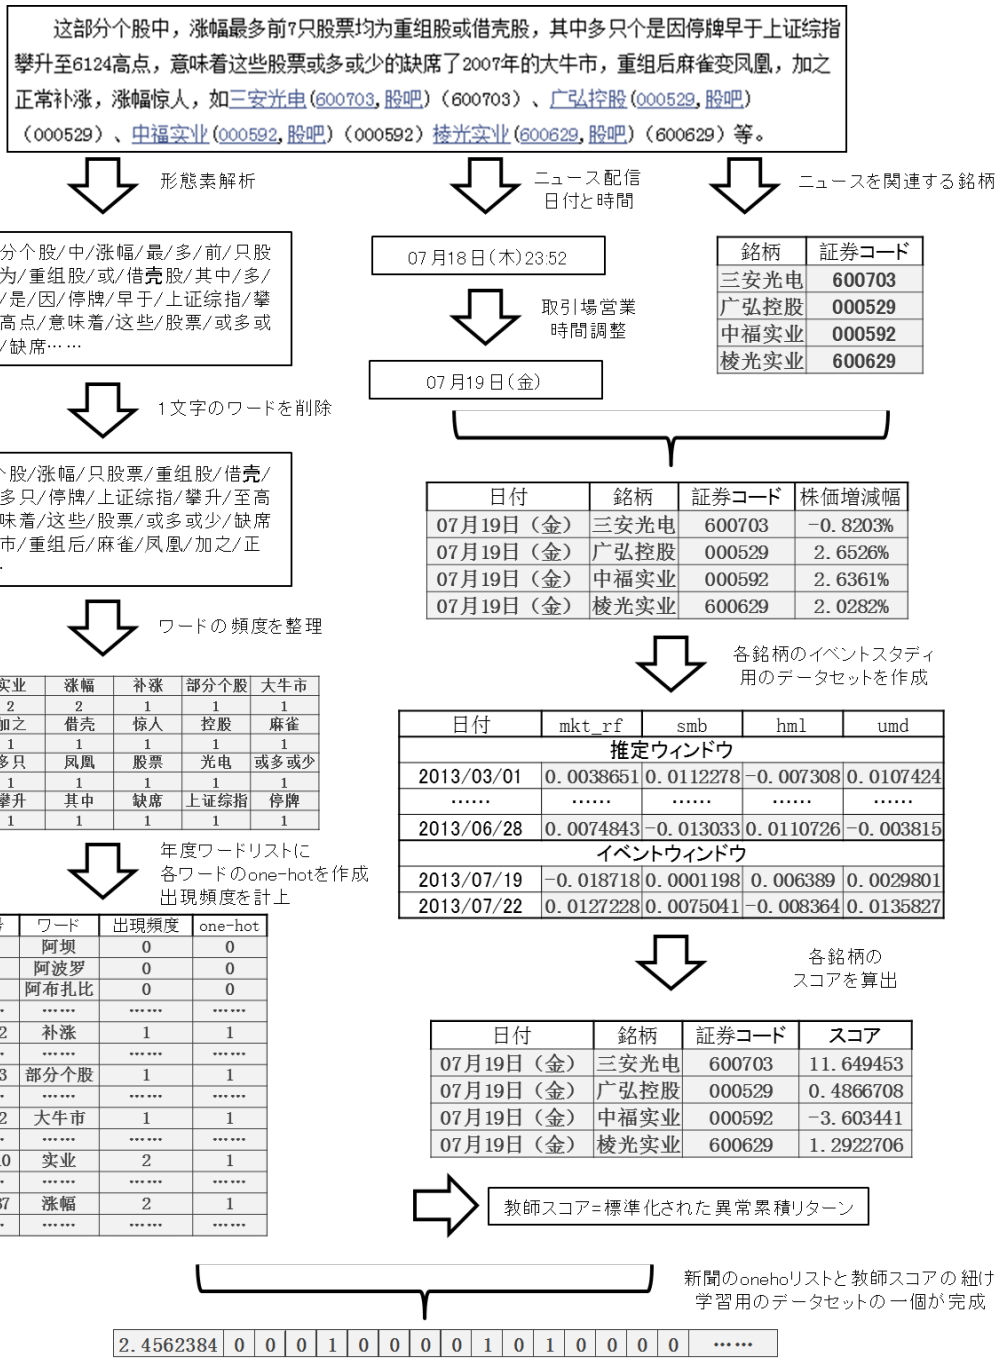

図 2　学習用データセットの作成過程の概略

[2] 中国中央財経大学;
http://sf.cufe.edu.cn/kxyj/kyjg/zgzcglyjzx/zlxzzq/98178.htm

次に、ニュースと関連する主要銘柄の情報を取得し、イベント・スタディにより各銘柄のリスク調整後のリターンを算出した[5]。ここで、イベント・スタディとは、企業の活動に関する情報の発表が、その企業の資産価格に与える影響を分析する手法である。ニュース配信日と株式価格変動の概念図を、図3に示す。

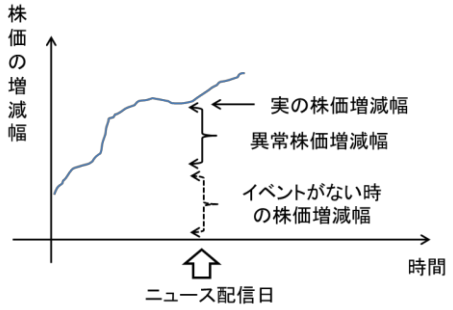

図3　ニュース配信日と株式価格変動の
の概念図

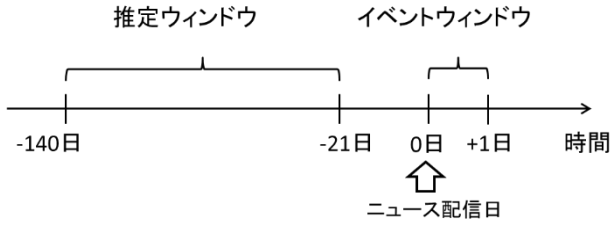

図4　ウィンドウの設定

イベント・スタディにおいては、ニュースごとに推定ウィンドウとイベントウィンドウを設定する。本分析では、推定ウィンドウはニュース配信日の140日前から21日前までの120日間、イベントウィンドウはニュース配信日当日からその翌日までとした。推定ウィンドウにおいて、Fama-Frenchの3ファクターモデルにより、パラメータを推定した[6]。

(2) ワードリストの作成

次に、2013年度のニュースからワードリストを作成する。本分析では、RのRwordsegパッケージ、形態素解析ツールAnsjを用いた。金融経済分野のワードを分析するため、証券、経済、金融分野のセル辞書を導入した。セル辞書は中国で有名な中国語入力システム（IME）であるSogou[3]が提供しているものである。

本分析では、1年分のワードリスト47,378語のTF-IDF値を算出し、それらのうち、上位10,000語を対象として分析を行った。

5.　分析結果

本研究では、2013年1月から4月のニュースを対象とし、分析を行った。同期間において出現した企業上位15社の内訳は、金融証券会社12社と、酒造業2社、電子部品メーカー会社1社であった。

本分析においては、単語のTF-IDの算出、単語極性の推計、推計した単語極性を用いたニュースの分類を行った。本分析にて得られたニュースの分類精度は、60%から70%の水準であった[4]。

6.　まとめ・今後の課題

本研究では、中国株式市場の日次データ、及びニュースデータを用いて、中国語の極性辞書の作成を試みた。本分析では、サンプル数を増加した分析、異なるデータソースを対象とした分析等は、今後の課題である。

参考文献

[1] Tetlock, P.C.: Giving Content to Investor Sentiment: The Role of Media in the Stock Market, Journal of Finance Vol.62, No.3, pp.1139-1168.(2007)

[2] Loughran, T. and B. McDonald : When Is a Liability Not a Liability? Textual Analysis, Dictionaries, and 10-Ks, Journal of Finance, Vol.66, No.1, pp.35-65. (2011)

[3] 五島 圭一, 高橋 大志.: 株式価格情報を用いた金融極性辞書の作成, 自然言語処理, Vol.24, No.4, pp.547-577, (2017)

[4] 関和広, 柴本昌彦: 銘柄固有の金融極性辞書の構築, 第18回人工知能学会, 金融情報学研究会(SIG-FIN), (2017)

[5] Campbell, J.Y., Lo., A.W., and MacKinlay, A.C.: The econometrics of financial markets, Princeton, NJ: princeton University press, 1997.

[6] Fama, E. F. and French, K. R.: Common Risk Factors in Returns on Stock and Bonds. Journal of Financial Economics, Vol.33 No.1, pp. 3-56. (1993).

[3] Sogou: https://pinyin.sogou.com/?r=shouji

[4] 本分析にて用いたサンプル数は限定的なものであることから、より大規模なデータを用いた分析等、詳細な分析は今後の課題として挙げられる。

感情分析を通じて見える経営者の特性と企業の関係
－日経 225 社を対象にした分析－

Empirical analysis of the relationship between the characteristics of company executives observed through facial emotions and their companies
- Analysis of Nikkei 225 firms -

税所篤大力 [1]　菅愛子 [1]　高橋大志 [1]

Atsutaka Saisho[1], Aiko Suge[1], and Hiroshi Takahashi[1]

[1] 慶應義塾大学大学院　経営管理研究科
[1] Graduate School of Business and Administration, Keio University

Abstract: Company executives play an important role in corporate activities. In this research, we focus on the characteristics of the top executive of each company, who make the important decisions.　We attempt to measure the facial emotional score of these executives from the photographs published on their firm's annual report. In addition, we create a narcissism index from the number of times these executives appear on their reports. Finally, we analyze how these emotional scores or narcissism indexes relate with their company's performance and behavior.

1　はじめに

経営者は企業活動において重要な役割を果たしている。しかし、近年の相次ぐ不祥事により、我が国の経営者はその在り方を問われている。日本の場合、安定株主が多いなどの理由で市場の圧力を受けにくいため、経営者はリスクが伴う投資や M&A といった決断を避け、組織をよどませ、停滞をもたらしやすい（Inoue et al., 2018）と言われている。Inoue et al.（2018）では、「平穏な生活追求仮説」と呼ばれるこの考えが、現在の日本企業にもあてはまることを実証的に検証している。

一方、世界的にみて、楽観的で、またリスク回避的でない経営者の方が M&A を積極的に実施している傾向がみられる（Malmendier & Tate, 2008）と言われている。では、積極的な投資を行う経営者であれば、企業の業績は維持、向上しやすいのだろうか。

海外では、そういった経営者の特性をナルシシズムと捉え、それが企業の業績や行動に与える影響について実証的に分析したもの（Ham et al., 2017; Chatterjee et al., 2007; Seybert, 2013）も少なくない。他方、我が国においては、日本企業を対象に経営者の特性と企業との関係について研究したものは海外に比べて圧倒的に少なく、中でもナルシシズムに言及したものは限定的である。また、そのような内容についてアニュアルレポートを用いて研究した論文として伊藤（2015）が挙げられるが、単年かつ情報・通信業のみを対象にしていることから、サンプルサイズも十分であるとは言い難い。本研究では、日経 225 社を対象に、5 年分のアニュアルレポートから取得したデータをもとに分析を行う。

2　分析アプローチと使用データ

分析には 2013 年から 5 年分の年次パネルデータを使用し、サンプル対象を日経 225 社とする。推定モデルは以下のとおりである。

$$Y_{it} = \sum_k \alpha_k E_{it}^k + \sum_l \beta_l X_{it}^l + \varepsilon_{it}$$

ここで、t 年における企業 i の業績および行動を表す変数をY_{it}、経営者の特性を表す変数をE_{it}^k、コントロール変数をX_{it}^lとして示している。ε_{it}は誤差項である。また、α_k、β_lは各変数へのパラメータを表し、本分析の関心はE_{it}^kの係数α_kに示される。

企業の業績および行動を表すY_{it}には、Chatterjee et al.（2007）や伊藤（2015）を参考に、「販管費率」、企業買収の規模を表す「子会社・関係会社の株式取得」、「ROA（総資産利益率）」などを用いる。これらはいずれも『日経 NEEDS』（日本経済新聞社）から入手、算出した。

さらに、経営者の特性を示すE_{it}^{k}には、大別して 2 種類の変数群を用いる。まず、Chatterjee et al.（2007）、Seybert（2013）や伊藤（2015）を参考に、アニュアルレポートにおける「経営者の登場回数」、「1 ページにおける経営者の写真やサインの占める割合」などをナルシシズム指標として使用する。次に、アニュアルレポート上に掲載される経営者の写真から測定した「ナルシシズム以外の感情スコア」を変数に加える。ナルシシズムに限らず、経営者の怒りや悲しみなどの感情に焦点を当てた研究（Madera & Smith, 2009）は存在しており、本稿ではナルシシズム以外の感情も企業の業績や行動に影響を与えているのではないかと考え、新たな試みとして追加した。なお、これらのデータは 2013 年から 2017 年分の日経 225 社のアニュアルレポートから収集し、感情スコアの測定には Microsoft 社の Emotion API を用いた。

ここでは、一部の結果として、日経 225 社の中の医薬品業界に属する企業 9 社を対象としたものを示している。推計に使用した変数の記述統計量は表 1 のとおりである。

3 分析結果

医薬品業界の企業をサンプルにした推計結果は、表 2 のとおりである[1)]。企業行動指標を被説明変数に設定した場合を Model 1～4、企業業績 ROA を設定した場合を Model 5 として示している。なお、Hausman 検定の結果、表 2 のすべてのモデルで変量効果モデルが採択された。

表 2 をみると、例えば Model 1 においてサイン面積が、Model 4 において登場回数が統計的に正に有意になっている。これはナルシシズム度が高ければ高いほど、売上高に占める投資の割合が増えることを意味している。また、Model 5 では登場回数が統計的に負に有意になっており、すなわちナルシシズム度が高ければ高いほど ROA が下がると解釈できる。以上の結果を踏まえると、ナルシシズム度の高い経営者は目立った投資を行う傾向にあるが、それは必ずしも業績の向上には結びついていない可能性がある。この結果は、情報通信業を対象として分析を行った伊藤（2015）の結果とも整合的である)。

4 まとめ

本稿では、日本企業 225 社を対象に、経営者の特性と企業行動や業績との関係を分析した。経営者の特性としては、アニュアルレポート上に収集した経営者の写真から測定した感情スコア、また経営者の登場回数などから作成したナルシシズム指標を使用した。なお、ここでは、日経 225 社のうち医薬品業界に属する企業 9 社を対象に行った結果を示している。

推計結果をみると、サイン面積が設備投資額売上高比率に、登場回数が負債比率にプラスの影響を与えていることが示された。また、登場回数が ROA にマイナスの影響を与えることが確認された。

これからは更なる先行研究の精査を進めるとともに、感情スコアやコントロール変数をも加えた分析を行うことを含めて、今後の課題としたい。

参考文献

[1] 伊藤卓志, 高橋大志: 経営者の特性と企業の行動および業績との関連性:アニュアルレポートの写真やサインから経営者のナルシシスト度を測定し関連性を探る, (2015)

[2] Charles Ham., Nicholas Seybert., Sean Wang.: Narcissism is a Bad Sign: CEO Signature Size, Investment, and Performance, UNC Kenan-Flagler Research Paper, No.2013-1, (2017)

[3] Chatterjee, A., and D. C. Hambrick.: It's all about me: Narcissistic Chief Executive Officers and their effects on company strategy and performance, Administrative Science Quarterly, 52, 351-386, (2007).

[4] Ham, C., M. Lang, N. Seybert, and S. Wang.: CFO Narcissism and Financial Reporting Quality, Journal of Accounting Research, (2017)

[5] Juan M. Madera, D. Brent Smith.: The effects of leader negative emotions on evaluations of leadership in a crisis situation: The role of anger and sadness, The Leadership Quarterly, 20, 103–114, (2009)

[6] Naoshi Ikeda, Kotaro Inoue, Sho Watanabe.: Enjoying the quiet life: Corporate decision-making by entrenched managers, Journal of the Japanese and International Economies, Volume 47, 55-69, (2018)

[7] Seybert, Nick.: Size Does Matter (in Signatures), Harvard Business Review, (2013)

[8] Ulrike Malmendier, Geoffrey Tate.: Who makes acquisitions? CEO overconfidence and the market's reaction, Journal of Financial Economics,89, 20–43, (2008)

[1)]本稿では、ナルシシズム指標のみを説明変数に加えたモデルで分析しているが、同様の手法を用いて、感情スコアも変数に加えたモデルで分析することも可能である。

表 1：記述統計量（医薬品業界）

変数名	平均	標準誤差	最小値	最大値
設備投資額売上高比率	0.044	0.054	0	0.362
研究開発費売上高比率	0.172	0.046	0	0.241
販管費率	0.439	0.136	0.167	0.665
負債比率	0.317	0.117	0.138	0.553
ROA	0.055	0.035	-0.033	0.161
子会社・関係会社株式取得	69359.1	146679.6	24	589144
ln子会社・関係会社株式取得	9.237	2.416	3.178	13.286
1回目登場ページ	9.311	7.546	0	32
1回目登場ページに写る人数	1.4	1.802	1	13
登場回数	4	1.446	1	8
写真比率	0.123	0.071	0.010	0.295
サイン面積比率	0.004	0.002	0	0.006
怒り	0.001	0.001	1.54E-10	0.005
軽蔑	0.004	0.008	5.00E-11	0.049
嫌気	0.001	0.003	6.41E-09	0.012
恐怖	0.000	0.000	1.99E-15	0.001
幸福	0.659	0.392	0.0000202	1.000
平常状態	0.309	0.366	3.64E-09	0.992
悲しみ	0.023	0.088	2.23E-12	0.534
驚き	0.003	0.009	3.29E-11	0.049
	0.2	0.405	0	1
	0.2	0.405	0	1
年ダミー	0.2	0.405	0	1
	0.2	0.405	0	1
	0.2	0.405	0	1

表 2：推計結果（ナルシシズム指標）

	Model 1 設備投資額 売上高比率	Model 2 研究開発費 売上高比率	Model 3 販管費率	Model 4 負債比率	Model 5 ROA
1回目登場ページ	-0.0001	0.0019**	-0.0024	-0.0002	0.0008
	[0.08]	[1.96]	[0.98]	[0.17]	[1.06]
1回目登場ページに写る人数	-0.0003	-0.0041	0.0030	-0.0031	0.0013
	[0.06]	[0.98]	[0.37]	[0.87]	[0.53]
登場回数	0.0090	-0.0061	0.0047	0.0098**	-0.0055*
	[1.47]	[1.17]	[0.43]	[2.00]	[1.65]
写真比率	-0.1901	0.0625	0.0235	0.0677	-0.0916
	[1.48]	[0.58]	[0.09]	[0.57]	[1.14]
サイン面積	9.2152*	1.5629	-4.8373	-2.6604	-1.5225
	[1.71]	[0.34]	[0.41]	[0.46]	[0.4]
年ダミー	yes	yes	yes	yes	yes
切片	-0.0088	0.2062***	0.5021***	0.2869***	0.0944***
	0.2	[5.52]	[6.19]	[5.55]	[3.65]
自由度修正済み決定係数	0.2203	0.2392	0.2116	0.0791	0.1842
サンプルサイズ	45	45	45	45	45

注：***:1%水準で有意，**:5%水準で有意，*:10%水準で有意，[ ]内は z 値を表す。