

組織のダブル・ループ学習にフォールトラインが与える影響の分析

○緑川和眞 高橋真吾 (早稲田大学)

Analysis of the Impact of Fault Lines on Double Loop Learning in Organization

* K. Midorikawa and S. Takahashi (University of WASEDA)

概要一 組織の長期的な発展においては、ダブル・ループ学習が重要であるとされる。しかし、この学習のプロセスである個人が持つ知識や価値観の組織全体への共有は、組織のグループ化をもたらすフォールトライン (FL) の形成により阻害されてしまうとされている。FL は、組織内で似た属性を持った個人同士が交流しやすくなることで、組織のパフォーマンスに影響を与えることがわかっている。本研究では、組織内の交流により形成される FL が変化する点に着目し、FL が組織学習に影響を及ぼす動的なメカニズムについて分析する。

キーワード: 組織学習, フォールトライン, Agent-Based Modeling, クラスタ分析

1 研究背景

組織は、日々発生するタスクの処理や課題の解決に向けて、組織内で知識の共有やスキルの継承などを行うことで環境に適応しようとする。組織学習とは、こうした環境適応のプロセスを表している¹⁾。また、企業活動として行われる組織学習には、シングル・ループ学習とダブル・ループ学習の2種類がある¹⁾。前者の学習は、組織内の既存の知識やルーティンを活用しながらタスクの遂行や問題の解決を行う改善の活動である。後者の学習は、組織で新たな知識やルーティンを開発・獲得することで、企業の存続や発展をもたらす活動である。組織を取り巻く環境の変化が大きい昨今の組織環境下においては、ダブル・ループ学習が特に重要であるとされる¹⁾²⁾。

組織におけるダブル・ループ学習を阻害する要因の1つに「Fragmented Learning (断片的な学習)」がある²⁾。これは、組織内の交流がうまく進まずに個人の持つ知識や価値観が組織全体に共有されていない状態を表す。ダブル・ループ学習を進めるためには、この断片的な学習をいかに回避して、組織活動をおこなっていくかが重要である。

2 先行研究

組織内で断片的な学習が発生する1つの要因として、フォールトライン (FL) の形成が挙げられる。Lau³⁾ は、組織内で性別や人種といった属性が同じ人同士でグループが作られることで、組織全体でのコミュニケーションが分断されてしまうような状況をFLの形成として位置付けている。FLは、似た属性を持った個人同士によるサブグループ (SG) 間に引かれる仮想的な分断線であるとされており、この分断線がSG間のコミュニケーションを抑制してしまう。また、FLの強さやSGの形成のされ方が組織のパフォーマンスに影響を与えることはこれまでの研究で明らかにされている。一般にFLによるSGの形成は、組織内のコンフリクトを引き起こすなど、組織にマイナスの影響を与えるとされている。一方Van⁴⁾ は、FLが組織に対してプラスの効果をもたらすことを示している。FLが性別、年齢、人種などのカテゴリー的な属性に基づいて形成された場合、SG間での交流や情報交換が妨げられるとしているが、FLが職務や専攻といった組織内のタスクに関連した属性に基づいて形成されると、SG間のコンフリクトが発生しにくくなり、むしろ交流や情報交換が活発にな

ることで組織のパフォーマンスが向上するとしている。FLの強さは、組織内の個人の属性を変数で定義することによって測定される。測定方法の1つであるASW (Average of Silhouette Width) と呼ばれるクラスタ分析は、測定対象者の人数に制限がなく、FLによるSGの数まで測定できるため、他の測定方法に比べて利点が多いことが挙げられており⁵⁾⁶⁾、いくつかの実証研究で利用されている⁷⁾。

また熊田⁸⁾ は、組織の多様性をFLの強さとSGの数で定量化し、エージェントベースモデル (Agent Based Model) を用いて個人同士の交流方法を変えながら、組織の多様性がパフォーマンスに与える影響を定量的に分析している。その結果、個人同士の交流方法に関わらず、FLが弱く、SG数が多い組織は、他の組織構造に比べてパフォーマンスが向上するという結果を得ている。しかし熊田⁸⁾ は、FLを形成する属性の種類を区別せず実験しており、属性の種類により組織のパフォーマンスに与える影響が異なるという点は考慮されていない。

3 研究課題と研究目的

これまで FL に関する知見の多くは、アンケート調査によるもので、性別や年齢、職種といった静的な属性から形成される FL を対象としている研究がほとんどである。しかし FL の形成は、個人が持つ静的な属性によるものだけでなく、知識や情報の伝達など組織内の日々のコミュニケーションからも行われる。そのため、FL と組織のパフォーマンスとの関係を考察するためには、組織内でコミュニケーションを行う中で FL の形成が変化していく点を考慮する必要がある。

本研究では、FL や SG が組織のパフォーマンスに与える影響のメカニズムを考察することを目的とし、メカニズムの説明として、組織内での知識や価値観の共有といったダブル・ループ学習のプロセスがどのように行われるかに焦点を当てる。まず、先行研究の知見を基に、カテゴリー的な属性による FL と、タスク属性による FL が形成される状況を想定し、FL が個人同士のコミュニケーションに及ぼす影響を考慮した組織モデルを構築する。次に、構築したモデルを用いて、FL や SG が異なる組織構造において、組織の学習活動やパフォーマンスがどのように変化するかについて分析する。

4 研究方法

4.1 エージェントベースモデル

本研究では、エージェントベースモデル(Agent Based Model)を構築してシミュレーション分析を行う。ABMでは、エージェントと呼ばれる個々の行為者が、エージェント同士の相互作用を通じて、組織全体に与える影響を分析することに適した手法である。本モデルでは、エージェントは自身の評価値を向上させるように、他のエージェントと交流・学習を行うことで相互作用が発生する。この相互作用が、FLの強さやSGの分かれ方によって影響を受けるように設計することで、組織全体での交流・学習にどのような影響を与えるかを分析する。

4.2 NKモデル

NKモデルはもともと生物進化や複雑系の数理システムで用いられる数理モデルとして用いられ、組織行動や組織学習の分野でも活用されている⁸⁾。NKモデルでは、0もしくは1の値をとるN個の遺伝子列が、K個の他の遺伝子座の値と関連し、全体の適応度が決定される。意思決定要素を $d_i \in \{0,1\}$ ($i = 1, \dots, N$)とし、意思決定列を d として $d = (d_1, \dots, d_i, \dots, d_N)$ と表現する。また、N個の意思決定要素に対してそれぞれ貢献度関数 $c_i(\dots)$ ($i = 1, \dots, N$)が与えられる。これは、意思決定要素 d_i の値のみでなく、他のK個の意思決定要素の値に依存する。Fig. 1は、 $K = 1$ の場合のNKモデルにおける要素間の依存関係と貢献度関数の例を示している。



Fig. 1: NKモデルの適応度関数 (例)

ある意思決定要素 d_i と他の依存するK個の意思決定要素を (d_1^1, \dots, d_i^K) とすると、NKモデルによる適応度の評価関数 $V(d)$ は、

$$V(d) = \frac{1}{N} \sum_{i=1}^N c_i(d_i, d_1^1, \dots, d_i^K)$$

と表される。

貢献度関数の値は一様分布 $U[0,1]$ の値をランダムに設定し、1シミュレーションごとに値を変更する。シミュレーション中は、貢献度関数の適応度の値は変化しない。

また本研究では、各エージェントの適応度の合計を組織全体の適応度として、1シミュレーション内での適応度の増減を分析する。

4.3 モデル設計

4.3.1 エージェントの内部モデル

エージェントは組織を構成する1個人を指し、互いに交流を行うことで自身の意思決定や価値観を変化させる。本研究では、組織内のFLはエージェントのカテゴリ的属性とタスク属性からそれぞれ形成されるものとする。カテゴリ的属性は、不変の属性として静的なFLを形成し、タスク属性は、エージェント同士の交流で変化することで動的なFLを形成するものとする。本研究で表現しているカテゴリ的属性の交流とタスク属性の交流は、実際の組織の交流におけるインフォーマルな交流、業務に関するフォーマルな交流をそれぞれ表しているものとする。

(1) カテゴリ的属性

各エージェントの属性値として、年齢や性別といったカテゴリ的属性を $category_attribute_{i,l} \in \{0,1\}$, $i \in \{1,2, \dots, AN\}$, $l \in \{1,2, \dots, category_length\}$ とする。

(2) タスク属性

各エージェントの専攻や専門性などタスクに対する知識や情報の有無を表す属性を $task_attribute_{i,k} \in \{0,1\}$ と表現する。 $k \in \{1,2, \dots, decision_length\}$ は、組織内に存在するタスクの種類を表しており、各タスクに対する知識の有無をタスク属性で表現する。エージェント同士の交流の際に、知識の共有を行うことでタスク属性値が変化する。

(3) 価値観属性

各エージェントのタスクに関する態度や考え方を表す属性を $value_{i,k} \in \{-1,0,1\}$ と表現する。価値観の値に関しては、 $value_{i,k} = -1$ は、タスク k を行う必要がないという考えを、 $value_{i,k} = 1$ は、タスク k を行う必要があるという考えを、 $value_{i,k} = 0$ は、タスク k へのバイアスがない状態をそれぞれ表す。

また、タスク属性の値と価値観属性の値は対応しており、 $task_attribute_{i,k} = 0$ ならば $value_{i,k} = 0$ とし、 $task_attribute_{i,k} = 1$ ならば $value_{i,k} \in \{-1,1\}$ とする。これは、エージェントが自身の保有している知識や情報が、タスクに関する考え方に影響することを表している。

(4) 意思決定列

各エージェントのタスクへの意思決定列を、 $decision_{i,k} \in \{0,1\}$ と表現する。 $decision_{i,k} = 0$ は、そのタスクを実行することを、 $decision_{i,k} = 1$ は、そのタスクを実行しないことをそれぞれ表す。

また、価値観属性と意思決定要素は対応している。 $value_{i,k} = 0$ ならば $decision_{i,k} \in \{0,1\}$ 、 $value_{i,k} = 1$ ならば $decision_{i,k} = 1$ 、 $value_{i,k} = -1$ ならば $decision_{i,k} = 0$ とする。

4.3.2 組織内の環境設計

先行研究⁷⁾を参考に、ASW (Average of Silhouette Width) によるクラスター分析を用いて、シミュレーション内の組織のFLの強さやSGの数を設定する。

$$s(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}}$$

$a(i)$ はエージェント i と同じクラスターに属する他の

エージェントとの距離の平均を表し、 $b(i)$ はエージェント i と隣接するクラスターに属するエージェントとの距離の平均を表す。エージェント間の距離は、属性のビット列のハミング距離で測定している。FL の強さは全てのエージェント i における $s(i)$ の平均値とし、SG 数はクラスター数とする。

本研究では、FL の強さや SG の数が異なる組織構造のパターンをいくつか表現するため、組織パターンごとに、各エージェントのカテゴリ的属性やタスク属性をそれぞれ設定している。Table 1 は、カテゴリ的属性とタスク属性それぞれを設定する際に表現した組織構造を示している。本研究では、カテゴリ的属性の FL の強さと SG 数を Table 1 より 9 パターン設定し、同様にタスク属性の FL の強さと SG 数を Table 1 より 9 パターン設定している。

Table 1: 本研究で設定した FL の強さと SG 数

FL の強さ	0.2 程度	0.5 程度	0.8 程度
SG 数 : 2	(0.2017,2)	(0.5325,2)	(0.7094,2)
SG 数 : 3	(0.2195,3)	(0.4827,3)	(0.7397,3)
SG 数 : 4	(0.2042,4)	(0.4812,4)	(0.7179,4)

4.3.3 エージェントの行動モデル

各エージェントは、エージェント間のカテゴリ的属性またはタスク属性に基づいて交流を行い、他のエージェントから意思決定を学習する。

(1) 学習相手の選定

組織内の他のエージェントに対して、自身と交流を行うエージェントを選択する。Lau⁹⁾ は、組織内の FL が強いほど SG 内での交流が活発になり、SG 外での交流が妨げられることを示している。本モデルでは、組織内の FL が強いほど、SG 内のエージェント同士で交流が行われるようにする。

(2) 学習相手の決定

(1) で選定したエージェントの中で、最も属性の類似度が高いエージェントを学習相手に決定する。ここで、属性の類似度は、属性ビット列のハミング距離としている。カテゴリ的属性に基づく交流を行う場合のエージェント i とエージェント j の類似度を次式で定義する。タスク属性に基づく交流の場合も同様である。

$$\text{Similarity}_{ij} = 1 - \frac{\sum_{k=1}^{\text{category_length}} |\text{category_attribute}_{ik} - \text{category_attribute}_{jk}|}{\text{category_length}} \times \text{similarity_Bias}$$

また、シミュレーションのステップごとに、各エージェントに対して属性列のうち 1 ブロックをランダムに選択する。選択した 1 ブロックの値を学習相手の属性値と比較し、値が同じ場合には similarity_Bias の値を乗じて類似度を算出する。値が異なる場合は similarity_Bias の値を乗じずに類似度を算出する。

Fig. 2 は、カテゴリ的属性の交流におけるエージェントの学習相手の決定のイメージ図である。

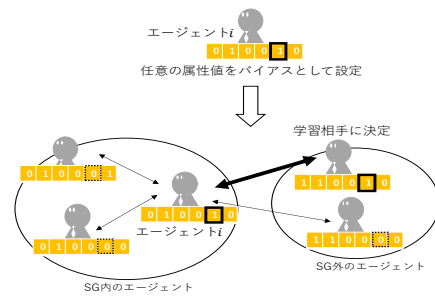


Fig. 2: 学習相手の決定

(3) 知識の共有

タスク属性の交流を行う場合、学習相手と知識の共有を行う。各エージェントは、自身の保有するタスクに関する知識 ($\text{task_attribute}_{i,k} = 1$) の中から、ランダムに 1 つの知識 k を選択して相手に共有する。

(4) 意思決定の学習

カテゴリ的属性の交流を行う場合、(2) で決定した学習相手の意思決定列と、自身の意思決定列を比較し、値が異なる意思決定要素のうち、ランダムに 1 つ選択して相手の意思決定を模倣する。

タスク属性の交流を行う場合、(2) で決定した学習相手から (3) より知識 k を受け取る。

ここで、自身も同じ知識 k を保有していた場合、(2) で決定した学習相手の適応度を自身の適応度と比較し、相手の適応度の方が高い場合に、意思決定の学習を行う。学習相手の意思決定列と、自身の意思決定列を比較し、値が異なる意思決定要素のうち、ランダムに 1 つ選択して相手の意思決定を模倣する。

学習相手から受け取った知識 k を保有していなかった場合、知識 k を受け取り意思決定の学習を行う。知識 k を受け取った際に、 $\text{task_attribute}_{i,k} = 1$ となることで、エージェント同士の交流でタスク属性が変化する。そして、受け取った知識 k に対応する $\text{decision}_{i,k}$ の意思決定を相手から模倣する。

Fig. 3 は、タスク属性の交流におけるエージェントの意思決定の学習のイメージ図である。

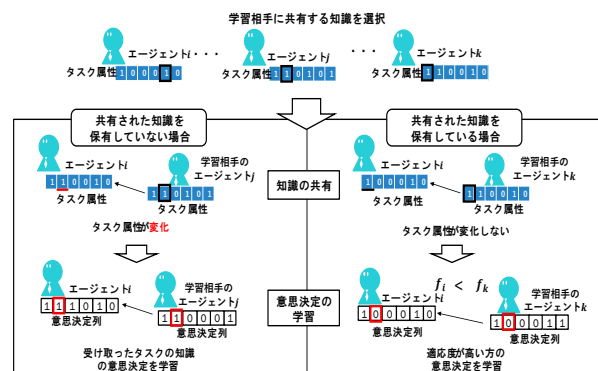


Fig. 3: 学習相手の決定

(5) 価値観の変更

(4) で自身の意思決定を変更した場合、自身の価値観の要素を変更する。 $\text{decision}_{i,k} = 0$ ならば $\text{value}_{i,k} = -1$ 、 $\text{decision}_{i,k} = 1$ ならば $\text{value}_{i,k} = 1$ とする。

(6) 学習後の意思決定の変更

突然変異確率 $p_mutation_decision$ に従い、自身の意思決定要素をランダムに変更する。

4.3.4 パフォーマンス評価

各エージェントの意思決定列に対して、NK モデルによる適応度評価を行う。エージェントの適応度を次式より定義する。

$$fitness_i = \frac{1}{N} \sum_{l=1}^N c_l(decision_l, decision_l^1, \dots, decision_l^K)$$

N の値は、エージェントの意思決定列の長さである $decision_length$ とする。また本研究では、組織全体のパフォーマンスを組織内の全エージェントの適応度の合計値として定義する。

5 シミュレーション実験

5.1 環境パラメータの設定

Table 2 は、本研究で使用した環境設定を表す。

Table 2: 環境設定

変数名	値	設定方法
試行回数 <i>Simulations_Num</i>	100	
1 シミュレーション 中のステップ数 <i>Simulation_Steps</i>	50	
エージェント数 <i>AN</i>	36	キャリブレーション
カテゴリー属性の 要素数 <i>category_length</i>	6	先行研究 ⁸⁾ より
意思決定要素数 <i>decision_length</i>	6	先行研究 ⁸⁾ より
意思決定 相互依存値 <i>K</i>	1	先行研究 ⁸⁾ より

エージェント数に関しては、4.3.2 でのクラスター分析の結果より設定を行った。

5.2 モデルの妥当性検証

本モデルの妥当性を検証するため、先行研究から得られている知見をスタイライズドファクト(SF)として設定し、モデル上で SF が表現されるようにパラメータ設定を行う。Table 3 は、本研究で採用した SF をまとめたものである。

Table 3: 再現したい SF

SF1	カテゴリー的属性の FL が強いほどパフォーマンスは減少する ⁴⁾⁹⁾ 。
SF2	カテゴリー的属性の SG 数が多いほどパフォーマンスは増加する ¹⁰⁾ 。
SF3	タスク属性の SG 数が多いほどパフォーマンスは増加する ¹⁰⁾ 。

5.3 妥当性の検証結果

Table 4 は、妥当性検証の結果より設定した 3 つのパラメータ値を示したものである。

Table 4: 妥当性検証のキャリブレーション結果

変数名	値
学習対象者の数 <i>Tournament_Size</i>	12
類似性のバイアス <i>Similarity_Bias</i>	0.2
意思決定の変異確率 <i>p_mutation_decision</i>	0.01

Fig. 4, Fig. 5 および Fig. 6 は、妥当性検証の結果を示しており、シミュレーションの前後での全体のパフォーマンスの増減値を比較している。妥当性検証での FL の強さや SG 数は、Table 1 より示している 9 パターンの値を初期値として設定して、それぞれ実験を行った。Fig. 4 と Fig. 5 は、シミュレーション内でカテゴリー的属性による交流のみが行われるように設定した場合の 9 パターンごとの結果を示している。また Fig. 6 では、シミュレーション内でタスク属性による交流のみが行われるように設定した場合の 9 パターンごとの結果を示している。Fig. 4 より、カテゴリー的属性において、SG 数が同じならば FL が強いほどパフォーマンスは減少しており(SF1)、Fig. 5 より、FL の強さが同程度ならば SG 数が多いほどパフォーマンスが向上している(SF2)。Fig. 6 より、タスク属性において、FL の強さが同程度ならば SG 数が多いほどパフォーマンスが向上している(SF3)。なお本研究では、1 シミュレーションを 100 試行行い、その平均値を結果として示している。

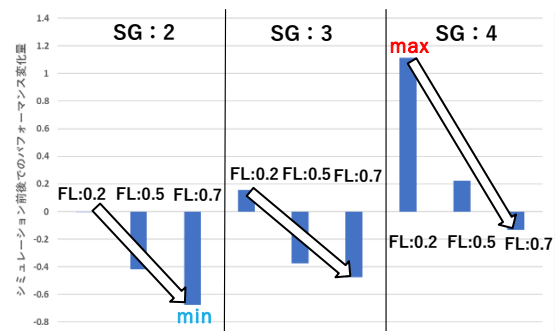


Fig. 4: SF1 の検証結果




Fig. 5: SF2 の検証結果

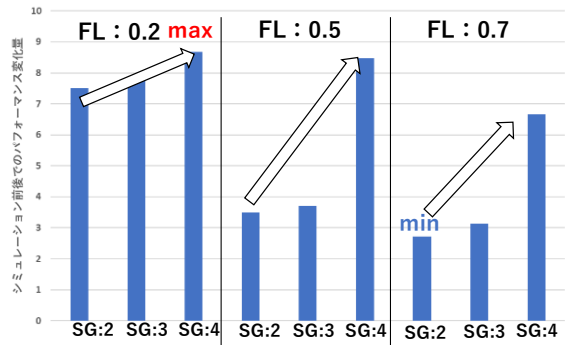


Fig. 6: SF3 の検証結果

5.4 シナリオ設計

本研究では、カテゴリー的属性の FL とタスク属性の FL が混在した状況を複数パターン設定し、組織のパフォーマンスがどのように影響されるかを分析するために、シナリオ分析を行う。

状況シナリオ 1 では、カテゴリー的属性の FL は弱く、SG 数は多い状況であり、カテゴリー的属性による組織構造の中で最も組織のパフォーマンスが向上するパターンである。また、タスク属性の FL は強く、SG 数は少ない状況である。

状況シナリオ 2 では、カテゴリー的属性の FL は中程度で、SG 数も中程度である状況であり、タスク属性の FL と SG 数も同様である。

状況シナリオ 3 では、カテゴリー的属性の FL は強く、SG 数は少ない状況であり、カテゴリー的属性による組織構造の中で最も組織のパフォーマンスが向上しないパターンである。また、タスク属性の FL は弱く、SG 数は多い状況である。

また、施策シナリオとして組織内のエージェントの交流方法を変化させる。各エージェントが、交流時にカテゴリー的属性とタスク属性のどちらに基づいて交流を行うかの意思決定を制御する。施策シナリオ 1 では、タスク属性による交流が行われやすくなり、施策シナリオ 2 では、カテゴリー属性による交流が行われやすくなる。施策シナリオ 3 では、どちらの交流も同程度行われる。

Table 5: シナリオ設定

状況シナリオ変数	シナリオ 1	シナリオ 2	シナリオ 3
カテゴリー的属性の FL の強さ	0.204	0.482	0.709
カテゴリー的属性の SG 数	4	3	2
タスク属性の FL の強さ	0.709	0.482	0.204
タスク属性の SG 数	2	3	4
施策シナリオ変数	シナリオ 1	シナリオ 2	シナリオ 3
カテゴリー的属性による交流割合	0.20	0.80	0.50

6 シミュレーション結果

6.1 シナリオ分析

本研究の結果として、シナリオごとの組織のパフォーマンスの推移を示す。また、組織内で学習がどのように進んでいるかを分析するために、各エージェントの価値観属性の分散を測定してその推移を結果として示す。なお、本研究のアウトプットは 100 試行における平均値を示している。




Fig. 7: 状況シナリオ 1 におけるパフォーマンス推移

Fig. 7 は、状況シナリオ 1 において施策シナリオを変えた場合のパフォーマンスの推移を表している。タスク属性による交流が活発に行われる施策シナリオ 1 の場合に、パフォーマンスが最も高くなり、シミュレーションのステップが進むにつれて向上していることがわかる。施策シナリオ 3 の場合は、施策シナリオ 1 ほどパフォーマンスは向上しなかったが、似たような推移でパフォーマンスは向上していることがわかる。カテゴリー的属性による交流が活発に行われる施策シナリオ 2 の場合は、パフォーマンスが最も低く、かつあまり変化しなかった。




Fig. 8: 状況シナリオ 1 における価値観属性の推移

Fig.8 は、各ステップでエージェントの価値観がどのように変化したかを属性値の分散を測定して表したものである。最もパフォーマンスが高かった施策シナリオ 1 では、シミュレーションの中盤まで価値観が発散しており、その後あまり収束していないことがわかる。エージェントそれぞれの適応度が高まるまで組織内で学習が進み、組織内でパフォーマンスを向上させる価値観が複数生成されたと考えられる。一方施策シナリオ 2 では、序盤で価値観が発散したものの、そこからすぐに収束してしまっている。エージェントそれぞれの適応度が高まるまで、組織内で十分に学習が進まず、組織内でパフォーマンスが向上しない価値観が共有されたと考えられる。施策シナリオ 3 では、施策シナリオ 2 に比べれば、比較的中盤まで価値観が発散しており、収束のスピードも緩やかであることから、組織のパフォーマンス向上をもたらす学習は、施策シナリオ 1>施策シナリオ 3>施策シナリオ 2 の順でうまく進んでいると考えられる。




Fig. 9: 状況シナリオ 2 におけるパフォーマンス推移




Fig. 10: 状況シナリオ 3 におけるパフォーマンス推移

Fig. 9 は、状況シナリオ 2 において施策シナリオを変えた場合のパフォーマンス推移を表しており、Fig. 10 は、状況シナリオ 3 において施策シナリオを変えた場合のパフォーマンス推移を表している。

どの状況シナリオの場合でも、施策シナリオの違いにおけるパフォーマンスは同様な推移をしていることがわかる。タスク属性による交流が活発に行われるほど組織のパフォーマンスは向上し、カテゴリー的属性による交流が活発に行われると組織のパフォーマンスは向上しないといえる。また、組織内での価値観属性の変化に関しては、カテゴリー的属性による交流では、パフォーマンスの向上に寄与しない価値観が組織内で共有がされており、タスク属性による交流では、パフォーマンス向上をもたらす価値観が組織内で複数生成されるが、価値観の共有化までは進んでいないといえる。

6.2 エージェントの交流方法を変化させた場合のシナリオ分析

6.1 のシナリオ分析では、シミュレーション中に各エージェントの交流方法が一定のシナリオを設定していた。しかし、状況シナリオが異なる場合のパフォーマンスや価値観の推移の違いがあまり見られなかった。そこで、設定した 3 つの状況シナリオは固定し、シミュレーションのステップごとにエージェントの交流方法が変化する場合の施策シナリオを新たに設定して分析を行う。

Table 6 は、新たに設定した 2 つの施策シナリオを示している。施策シナリオ 4 は、シミュレーションの序盤はタスク属性による交流が活発であるが、活動が進むにつれてカテゴリー的属性による交流が活発になっていくように設定した。また、施策シナリオ 5 は、シミュレーションの序盤はカテゴリー的属性による交流が活発であるが、活動が進むにつれてタスク属性による交流が活発になっていくように設定した。

Table 6: 新たに設定した施策シナリオ

施策シナリオ 変数	シナリオ 4	シナリオ 5
ステップごとの エージェントの 交流方法	カテゴリー的属性の 交流が増えていく	タスク属性の交 流が増えていく

Fig 11 は、施策シナリオ 4 の場合での状況シナリオごとのパフォーマンスの推移を示す。どの状況シナリオの場合でもパフォーマンスが向上していることがわかる。特に、タスク属性の FL が弱い状況シナリオ 3 の場合にパフォーマンスが最も向上している。施策シナリオ 4 では、シミュレーションの序盤はタスク属性による交流が活発に行われるため、タスク属性の FL が弱いほど、組織内でパフォーマンスが向上するまで学習が進んでいると考えられる。




Fig. 11: 施策シナリオ4におけるパフォーマンス推移

Fig 12 は、施策シナリオ4の場合での状況シナリオごとの価値観属性の分散の推移を示す。どの状況シナリオの場合でも、タスク属性による交流が活発に行われるシミュレーションの序盤から中盤にかけて価値観の分散が増加しており、新たな価値観の生成が行われていることがわかる。その後は、活発になっていくカテゴリー的属性による交流により、価値観の分散が緩やかに減少して、組織内で価値観の共有が進んでいると考えられる。最もパフォーマンスが高かった状況シナリオ3では、他の状況シナリオと比較して常に価値観の分散が大きくなっており、組織内でパフォーマンスを向上させる価値観の形成がより進んだと考えられる。




Fig. 12: 施策シナリオ4における価値観属性の推移

Fig 13 は、施策シナリオ5の場合での状況シナリオごとのパフォーマンスの推移を示す。状況シナリオ1と状況シナリオ2で組織のパフォーマンスが向上しており、状況シナリオ3ではパフォーマンスが減少している。施策シナリオ5では、活動の序盤はカテゴリー的属性による交流が活発に行われるため、カテゴリー的属性のFLが強い組織構造である状況シナリオ3では、組織全体で交流・学習が進まずにパフォーマンスが減少したと考えられる。カテゴリー的属性のFLがそれほど強くない組織構造である状況シナリオ1や状況シナリオ2では、序盤である程度組織内での学習が進み、特にFLが弱い状況シナリオ1では、他の状況シナリオの場合よりも学習が全体に進んだことで最もパフォーマンスが向上したと考えられる。

また、どの状況シナリオの場合でも、活動の中盤以降に活発に行われるタスク属性による交流で組織パフ

フォーマンスの向上が見られなかった。これは、活動の序盤で活発であったカテゴリー的属性による交流により、組織内で価値観の共有・収束が進んでしまったため、その後のタスク属性による交流が行われても、パフォーマンスの向上をもたらす学習や価値観の生成が行われなかったと考えられる。




Fig. 13: 施策シナリオ5におけるパフォーマンス推移

Fig 14 は、施策シナリオ5の場合で状況シナリオごとの価値観属性の分散の推移を示す。示している。どの状況シナリオの場合でも、序盤に価値観の分散が発散してすぐに収束している。カテゴリー的属性の交流により組織内で価値観の共有が進んだことで、活動の中盤以降に行われるタスク属性の交流が行われても、新たな価値観の生成が行われていないことがわかる。状況シナリオ1は、他の状況シナリオと比較して組織パフォーマンスが向上しているが、価値観が最も収束している。つまり、組織のパフォーマンスを向上させる価値観が組織内に生成され、かつその価値観が組織全体に共有されている状況であると考えられる。




Fig. 14: 施策シナリオ5における価値観属性の推移

施策シナリオ4や施策シナリオ5の結果から、タスク属性のFLが弱い組織構造では、活動の序盤にタスク属性による交流を活発に行うことで組織のパフォーマンスが向上することがわかった。また、カテゴリー的属性のFLが弱い組織構造では、活動の序盤にカテゴリー的属性による交流を活発に行い、その後タスク属性による交流を活発に行うことで組織パフォーマンスの向上と、組織内での価値観の共有が進んでいた。状況シナリオ3と施策シナリオ5の場合で、パフォーマンス向上をもたらす価値観の生成と組織全体への共

有というダブル・ループ学習のプロセスがうまく進んでいる状況が発生する可能性を見出した。

7 結論

本研究では、組織内で形成される FL の強さやその種類、SG 数が異なる状況で、組織のパフォーマンスや学習活動がどのように変化するかを分析した。カテゴリー的属性の FL が弱く、タスク属性の FL が強い場合であっても、カテゴリー的属性による交流を抑制し、むしろタスク属性による交流を促進することで組織のパフォーマンスは向上することが示唆された。カテゴリー的属性の FL が強くない状況とは、年齢や性別といった属性が近い人同士が集まっているような組織であり、組織全体での交流や価値観の共有は行われやすいといえる。しかし、組織のパフォーマンスに直接には寄与しないインフォーマルな交流であるため、組織内である程度抑制する必要があることがわかる。反対に、タスク属性による交流は組織内でのフォーマルな交流と位置付けることができるため、組織のパフォーマンス向上をもたらすといえる。また、タスク属性の FL が強い状況とは、同じ職種や部署内といった同じような知識や情報を持った人同士で交流が進んでいるような組織であり、異業種や部署間での交流があまり行われなような状況が発生している。そのため、組織全体での価値観の共有は起こりづらいが、同じ職種や部署内での交流により、組織のタスク処理が進むことでパフォーマンスは向上するといえる。また、フォーマルな交流とインフォーマルな交流をコントロールする場合は、組織内の FL が弱い属性に基づいた交流をまず十分に行っていくことで組織のパフォーマンスが向上することがわかった。特に、カテゴリー的属性の FL が弱い組織状況では、まずインフォーマルな交流を十分に行い、徐々にフォーマルな交流を増やしていくことで、組織のパフォーマンスの向上と価値観の共有が行われ、組織のダブル・ループ学習がうまく進む可能性があることが示唆された。

参考文献

- 1) 安藤文江：組織学習論，103 ページ/125 ページ，新世社 (2019)
- 2) R. Espejo : Organizational Transformation and Learning, p.146/p.175, John Wiley & SONS (1996)
- 3) Lau, D. C. and Murnighan, J.K : demographic diversity and faultlines : The compositional dynamics of organizational groups, Academy of Management Review, **Vol.23** -No.2, p.325/p.340 (1998)
- 4) Van Knippenberg, D., De Dreu, C. K, Homan A. C. : Work group diversity and group performance:An integrative model and research agenda, Journal of Applied Psychology, **Vol.89** -No.6, p.1008/p.1022 (2004)
- 5) 鈴木竜太, 松本雄一, 北居明：フォールトラインの概念と分析手法, 国民経済雑誌, **第 211 巻** -6 号, 53 ページ /88 ページ (2015)
- 6) Meyer, B., Glenz, A. : Team Faultline Measures:A Computational Comparison and a New Approach to Multiple Subgroups, Organizational Research Methods, **Vol.16** -No.3, p.393/p.424 (2013)
- 7) 内藤知加恵: フォールトラインに関するレビューと考察,

早稲田大学大学院商学研究科, 商学研究科紀要, **第 79 巻**, 103 ページ/125 ページ (2014)

- 8) 熊田ふみ子, 倉橋節也: 多様性が組織の成果に及ぼす影響: フォールトラインによる考察, 経営情報学会誌, **第 28 巻** -4 号, 189 ページ/209 ページ (2020)
- 9) Lau, D. C., & Murnighan, J. K. : Interactions within groups and subgroups: The effects of demographic faultlines, Academy of Management Journal, **Vol.48** -No.4, p.645/p.659 (2005)
- 10) Andrew M. Carton, and Jonathon N. Cummings : The Impact of Subgroup Type and Subgroup Configurational Properties on Work Team Performance, Journal of Applied Psychology, **Vol. 98** -No. 5, p.732/p.758 (2013)