

機械学習を用いたサプライチェーン戦略パターン分析

日大生産工（学部） ○松本涼平 日大生産工 大江秋津

1 まえがき

近年の市場のグローバル化、ニーズや競合他社の多様化といった複雑な環境下で、多くの組織で構成されるサプライチェーン（以下 SC）全体の最適化問題が複雑化している。SC は、メーカーで製造されたものが、卸売りや小売りなどの流通企業を通じて、市場へ提供される一連の流れであり、メーカーを川上、小売を川下になぞらえる¹⁾。また、企業や部門の垣根を超え、SC を効率化する手法をサプライチェーンマネジメント（以下 SCM）という。本研究は、エレファントゲームと呼ばれる SC に関わる業務に携わっている社会人が実際に参加した、オンラインサプライチェーンゲームデータを利用する。本研究の目的は、エレファントゲームで得られたシミュレーションデータの最適な戦略パターンを分類する手法の選択を目的とする。

2 SCM における戦略分類

SC の最適化の指標の代表的なものに、在庫費用（在庫管理費用と機会損失費用の合計）とブルウィップ効果（bullwhip effect）がある。ブルウィップ効果は、SC の川下から川上に近づくほど、発注量の変動が増幅される現象である。在庫不足を避けるために、多めに発注することが、SC 内で川下から川上に向かって時間差で発生することが大きな要因である。その結果、川上に近いほど、市場の需要がみえないため、発注量の決定が困難となり、多くの問題を引き起こす²⁾。累積在庫費用は、各組織が自らの費用を確認すれば意識しやすい問題であるが、ブルウィップ効果は他組織の情報が見ることが困難な SC 内において、察知することや対策をとることが非常に困難である。3 階層（メーカー、卸、小売）の SC によるエレファントゲームを実施した結果、各階層の累積在庫費用を確認すると、各階層のどこかに累積在庫費用の負担を押し付ける形で最適化しているものと、ある程度分散して負担しているものがあった。また、SC 全体の累積在庫費用とブルウィップ効果の相関が小さく、累積在庫費用を抑える戦略が必ずしも、ブルウィップ効果を抑制しているとは

限らないことが明らかとなった。各階層の累積在庫費用と SC の累積在庫費用とブルウィップ効果は、SCM 内で検討した戦略の結果であり、本研究は分類基準として着目した。

3 分析手法

機械学習を行うソフトウェアは Python、プログラム開発用のプラットフォームに Jupyter Notebook を用いた。データは、エレファントゲームの各階層（メーカー、卸、小売）の累積在庫費用と SC の累積在庫費用とブルウィップ効果（式2）を用いる³⁾。利用データ件数は12件である。

$$B_i = \frac{\text{Var}[q_i]}{\text{Var}[D]} \quad (1)$$

$$\text{Var}[B_1, B_2, \dots, B_i] \quad (2)$$

B_i : i 段階目の業者におけるブルウィップ効果。本研究は、メーカーが 1 段階目、卸売が 2 段階目、小売が 3 段階目とする。

q_i : i 段階目の業者が 1 段階上流へ発注する発注量。メーカーにおいては、生産量。

D : 最終需要量で、今回のゲームでは市場から得る需要量。

$\text{Var}[\]$: 分散

戦略分類のための機械学習手法は、k近傍法、k-means クラスタリング、凝集型クラスタリング、DBSCAN、階層型クラスタリングという5種類を選択した。分析では、分類結果の評価も行った。

k 近傍法 (k-nearest neighbor algorithm, k-NN) は、得られたデータから距離が近い順に、任意の K 個を取得し、多数決でデータが属するクラスを推定する。k-means クラスタリング (k-means clustering) は、データのある領域を代表するクラス重心を見つける手法である。凝集型クラスタリング (agglomerative clustering) は、個々のデータを個別のクラスタと考え、最も類似した 2 つのクラスタを併合する処理を何らかの条件が満たされるまで繰り返す。階層型クラスタリングは、凝集型クラスタリングと同様の手法で分類するが、階層構造で

The Analysis of Supply Chain Strategic Pattern Recognition Using Machine Learning

Ryohei MATSUMOTO and Akitsu OE

表現する。DBSCAN とは、ベクトルで構成された空間で、点が密集する部分を見つけて分類する手法である。

4 実験結果および検討




図1. k-meansと凝集型クラスタリングの分析結果




図2. DBSCANでの分析結果




図3. 階層型クラスタリングでの分析結果

5種の分析手法を実施した結果の一部が、図1、図2、図3である。分析の際に、k-means と凝集型クラスタリングは、データ件数が少ないことから3種類に分類するように設定した。分析の結果、k-means (図1) は3種類、DBSCAN (図2) は、2種類に分類した。さらに、凝集型クラスタリング (図1) は、k-meansとまったく同じ3種類に分類した。凝集型クラスタリングとk-meansは、異なる分析手法に関わらず、まったく同一の結果ということは、この分類結果の頑強性を説明するものといえる。

図3の階層型クラスタリングを見ると、2本の点線のうち、下部の点線が階層図を3分類している。凝集型クラスタリング内の緑の点(図1)が、階層型クラスタリ

ングの3-9番のindexの緑の群 (図3) と一致する。次に2点ある赤は、5、6番のindex群に対応する。つまり、今回は分類を3種類に指定したが、k-meansと凝集型クラスタリングとで分類した緑の点群 (図1) の背景には、階層型クラスタリング (図3) で観察すると、さらに細かい分類が存在していることがわかる。

さらに、k-meansクラスタリングと凝集型クラスタリングの分類結果のうちランダムに40%のデータを教師データにしたところ、k-meansの結果がk近傍法による分類と一致との一致は、59.9%であった。

最後に分類の妥当性に関する評価を行った。クラスタリング分類の妥当性の評価指標であるシルエット係数を用いて「正解なし評価」を行った結果、k-meansは0.66、凝集型クラスタリングは0.66、DBSCANは0.30という結果が出た。いずれも正の値であるため、分類に問題はないが、このスコアは結果が1に近づくほど良い分類と評価されるため、k-meansと凝集型クラスタリングが最も良い結果といえる。

5 考察

本研究の機械学習による戦略分類結果から、k-meansと凝集型クラスタリングが、今後の戦略分類候補となることが明らかとなった。しかし、この両分類手法が全く異なる分析手法にも関わらず同じ分類になったことは、今後データを増やしてさらに妥当性を検証していく必要がある。また、k-meansと凝集型クラスタリング (図3) 内の緑の点が、最も密集した分類であることが明らかになった一方で、その背後には多くの分類が隠れていることが明らかとなった。つまり、データ数が増加すれば、さらに多くの分類が生まれる可能性が明らかとなった。今後は、この戦略分類結果を利用した統計分析を行って、SCMの最適化の要因を検証することが重要な課題である。

「参考文献」

- 1) D.スミチ・レビ,E. スミチ・レビ,P.カミンスキ,サプライ・チェーンの設計と管理-コンセプト・戦略・事例,朝倉書店,(2002).
- 2) Lee,H.L., Padmanabhan,V. and Whang,S. ,Information Distortion in a Supply Chain:The Bullwhip Effect,Management Science,Vol.43,No4,(1997年)p546-558.
- 3) 織田慎一郎,森崇,大江秋津,「社会実験によるSCMシミュレーション研究-組織間対話と戦略がブルウィップに与える影響-」第48回(平成27年度) 日本大学生産工学部学術講演会,(2015)p1021-1024.
- 4) Andreas C. Muller,Sarah Guido,中田秀基,Pythonではじめる機械学習—scikit-learnで学ぶ特徴量エンジニアリングと機械学習の基礎,オイラリージャパン,(2017)p177-189.