

## サプライチェーンにおける合意可能価格予測を考慮した自動交渉戦略

清水 拓夢†

藤田 桂英‡

†東京農工大学 工学部 情報工学科

‡東京農工大学大学院 工学研究院 先端情報科学部門

## 1 はじめに

国際自動交渉エージェント競技会 International Automated Negotiating Agents Competition (ANAC) は、2010年から始まり、過去12回開催されている [1]。ANACは複数のリーグから成り、そのうちの一つに Supply Chain Management League (SCML) がある [2]。SCMLでは、サプライチェーンネットワークにおける企業間の交渉を題材として複数のエージェントとの並列交渉が行われる。さらに、SCMLには複数の Track が存在し、その一つに OneShot Track がある。OneShot Track では、2層の工場にエージェントがそれぞれ割り当てられ、並列交渉により取引量を決定する。

本研究では、LSTM を用いた合意可能価格予測を行い、それを考慮した SCML に有効な交渉戦略を提案する。提案した戦略を評価する際には、競技会に出場したエージェントとのシミュレーションを行う。参加させるエージェントの種類や数、各工場のコストなどを変化させ、幅広い交渉環境での実験を行い、提案エージェントが高い獲得効用値を得ていることを示す。

## 2 問題設定

本論文では、SCML の OneShot Track で用いられている環境を用いるため、プロトコルやドメインなどは競技会の規定 [3] に従う。OneShot Track では、エージェントは2層のサプライチェーンに含まれる工場一つを担当し、異なる層のエージェントと交渉を行う。各層には複数のエージェントが配置されているため、本研究で扱う問題は、並列二者間交渉問題となる。

OneShot Track では交渉に重点をおいた特殊な環境を想定している。まず、交渉において合意が成立した際、商品の配送にかかるコスト（時間など）は0となる。また、その日の交渉で売れ残った商品についてはコストを支払った上で全て破棄される。さらに、参加者のエージェントは、毎日決められた量の取引を行う必要がある。

## 3 提案手法

本章では、合意可能価格予測を組み込んだ SCML において有効な交渉戦略 PAPA (Predict Agreeable Price Agent) について述べる。本戦略は、2021年に開催された OneShot Track において準優勝したエージェントである Gentle をベースとして作成した。

## 3.1 合意可能価格の予測

事前に行ったシミュレーションの交渉データを用いて、対戦するエージェントの合意可能価格を機械学習により予測し、交渉に活用する。2021年に開催された SCML OneShot Track の決勝に参加した7体のエージェントを用いてシミュレーションを行い、訓練、評価のための交渉データを取得した。交渉データには、売り手の数や買い手の数などの環境データ、相手と自分のオファー価格や量、これまでの合意価格などの時系列データが含まれる。本研究では、入力を交渉データ、出力を合意可能価格として LSTM を用いて教師あり学習を行った。ここでの合意可能価格とは、相手が合意可能な価格のうち自分にとって最良な価格を指す。

## 3.2 オファー戦略

オファー戦略では、相手に提案する製品の価格および量を決定する。

製品価格の決定には、Time-dependent model を改良したものをを用いる。エージェント  $a$  に対する取引価格帯の上限  $p_a^{\max}$  および下限  $p_a^{\min}$  を設定し、その価格帯で時間が経つにつれて相手に譲歩した価格でオファーをする。この上限  $p_a^{\max}$  および下限  $p_a^{\min}$  は、相手とこれまでに合意があるかないかで異なる。

交渉相手とこれまでに合意したことがある場合、その合意価格を用いてオファーを決定することで受諾されやすくなる。これは、OneShot Track では常に決められた量の取引を行う必要があり、エージェントは毎日継続して契約を結ぼうとするためである。 $p_a^{\max}$  および  $p_a^{\min}$  は、次に示す式 (1) と式 (2) で計算する。

$$p_a^{\min} = \min(p_i^{\max} \times 0.97, p_a^{\text{worst\_contract}} \times (1 - s^{\text{worst\_contract}}))$$

if selling

(1)

$$p_a^{\max} = \max(p_i^{\min} \times 1.03, p_a^{\text{worst\_contract}} \times (1 + s^{\text{worst\_contract}}))$$

if buying

(2)

Automated negotiation strategies considering prediction of agreeable price in supply chain managements

†Department of Computer and Information Sciences, Faculty of Engineering, Tokyo University of Agriculture and Technology

‡Division of Advanced Information Technology and Computer Science, Institute of Engineering, Tokyo University of Agriculture and Technology

$p_i^{\max}$  および  $p_i^{\min}$  は、システムによって決定される  $i$  日目における単価の上限および下限である。  $p_a^{\text{worst\_contract}}$  は、エージェント  $a$  とのこれまでの合意の中で PAPA にとって最も悪い価格を表す。  $s^{\text{worst\_contract}}$  は、  $p_a^{\text{worst\_contract}}$  を微増減させるためのスラック変数であり、大きいほど相手に譲歩したオファー価格となる。

一方、交渉相手とこれまでに合意がない場合、価格の基準が存在しない。そのため、学習したエージェント  $a$  に対する合意可能価格  $p_a^{\text{agreeable}}$  を基準として、次に示す式 (3) および式 (4) によりオファー価格を決定する。

$$p_a^{\min} = p_a^{\text{agreeable}} \times (1 + s^{\text{offer}}) \quad \text{if selling} \quad (3)$$

$$p_a^{\max} = p_a^{\text{agreeable}} \times (1 - s^{\text{offer}}) \quad \text{if buying} \quad (4)$$

$$s^{\text{offer}} = 0.0 - 0.2 \times \min\left(\frac{i/I}{0.3}, 1\right) \quad (5)$$

$i$  は現在の日数であり、  $I$  はシミュレーションにおける最大日数である。  $s^{\text{offer}}$  は、合意がない場合のオファーに関するスラック変数であり、大きいほど自分にとって良い価格でオファーを行う。

製品量については、システムにより決められた量を満たせるようにオファー量を決定する。オファー量は、次に示す式 (6) により求める。

$$q_o = \min(q_{a,i,j-1}^{\text{opp}}, q^{\text{need}}) \quad (6)$$

$$q^{\text{need}} = \sum_{c \in C_i^{\text{ex}}} q_c - \sum_{c \in C_i^{\text{neg}}} q_c \quad (7)$$

$C_i$  は、  $i$  日目に Gentle が交渉により得られた契約の集合であり、  $q_{a,i,j-1}^{\text{opp}}$  は、  $i$  日目  $j$  ラウンドにエージェント  $a$  から受け取ったオファー量である。

### 3.3 受け入れ戦略

受け入れ戦略では、受け入れるかどうかを判断するための閾値  $t = (p_t, q_t)$  を用いる。 PAPA は、価格の条件を満たしたオファーを、量の条件を満たすまで受け入れる。製品価格  $p_t$  を求める際には、オファー戦略と同様に Time-dependent model を改良したものをを用いる。オファー戦略と同様に、上限  $p_a^{\max}$  または下限  $p_a^{\min}$  を交渉中に動的に変化することにより、状況に応じて適切な価格を決定する。対戦相手とこれまでの合意がある場合は、その合意価格を用いて閾値を決定する。一方、合意がない場合は取引価格帯の中央値を閾値として設定する。

## 4 実験

提案した戦略を評価するため、交渉シミュレーション実験を行う。学習には Pytorch を用い、実験には自動

交渉プラットフォームである NegMAS[4] を用いる。

実験では、対戦相手として 2021 年に開催された SCML OneShot Track の決勝に参加した 7 体のエージェントを用いる。交渉プロトコルおよびドメインは、OneShot Track のそれに従い、25 種類の環境設定で実験を行った。

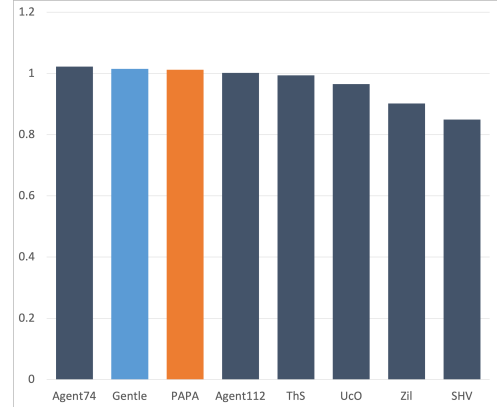


図 1: 交渉シミュレーションの結果

提案した手法における合意可能価格の予測精度は、MAE で 11 % であった。

図 1 は、シミュレーションにより最終的に獲得した効用値の平均値を比較した結果である。提案手法を組み込んだエージェントは PAPA、戦略のベースとなったエージェントは Gentle である。結果から、PAPA は Gentle と同程度の効用値を得たが、ベースとなる戦略を越えることはできなかった。これは、合意可能価格の予測精度が良くないために相手が合意することのできない価格でオファーをしたことが原因である。

## 5 まとめ

本研究では、SCML OneShot Track において有効な合意可能価格予測を考慮した交渉戦略を提案した。実験により基にした戦略と同程度の効用値を得た。

## 参考文献

- [1] Tim Baarslag, Reyhan Aydođan, Koen V. Hindriks, Katsuhide Fujita, Takayuki Ito, and Catholijn M. Jonker. The automated negotiating agents competition, 2010–2015. *AI Magazine*, 36(4):115–118, Dec. 2015.
- [2] Yasser Mohammad, Enrique Areyan Viqueira, Nahum Alvarez Ayerza, Amy Greenwald, Shinji Nakadai, and Satoshi Morinaga. Supply chain management world. In *PRIMA 2019*, pages 153–169, Cham, 2019.
- [3] Y. Mohammed, E. Areyan Viqueira, A. Greenwald, K. Fujita, M. Klein, S. Morinaga, and S. Nakadai. Supply chain management league (oneshot), 2021.
- [4] Yasser Mohammad, Shinji Nakadai, and Amy Greenwald. Negmas: A platform for situated negotiations. In *Recent Advances in Agent-based Negotiation*, pages 57–75, 2021.