

セキュアマルチパーティ計算による PS 学習法について


Profit Sharing method for Secure Multi-party Calculation

牧野 隼輝* 宮島 廣美* 重井 徳貴* 宮島 洋文**
 (*鹿児島大学大学院理工学研究科) (**長崎大学大学院医歯薬学総合研究科)

1 はじめに

データマイニングに関して、データを秘匿したまま処理を実現する研究が行われている。特に個々の秘匿データを分散して記憶や計算処理を実現する研究が注目されている [1, 2]。本稿では、個々の秘匿データを分散した状態で計算処理や記憶を行う SMC に着目し、強化学習に用いる学習データを別々のサーバに分割送信して計算処理や記憶を行う手法を提案し、その有効性を示す。

2 セキュアマルチパーティ計算 (SMC)



データを秘匿したまま処理を行う方法として、本稿で用いる Secure Multi-party Calculation (SMC) について説明する。ここでは、クライアントと K 個のサーバからなるモデルによる、

実数データ x に対する関数 $f(x)$ の計算を用いて SMC の計算処理を説明する [2]。 i を正の整数として $Z_i = \{1, \dots, i\}$ とする。はじめに、クライアント側で実数データ x をランダムに K 個のデータ $x_j (j \in Z_K)$ に分割する。 j 番目のデータ x_j は j 番目のサーバに送信される。サーバでは送られたデータを用いて $f_j(x_j)$ の処理が行われる。最終的な結果はクライアント側で $f_j(x_j)$ を加算することで得られ、 $\sum_{j=1}^K f_j(x_j)$ と表される。問題は $f(x)$ と $\sum_{j=1}^K f_j(x_j)$ がどのようにデータ分割と計算を行えば一致するかということである。

3 Profit Sharing

Profit Sharing (PS) は、強化学習の代表的手法の 1 つである。 S を状態の集合、 A を行動の集合とすると、状態 $s \in S$ と行動 $a \in A$ に対応する重み $\omega(s, a)$ を学習により決定する。学習時の状態 s_i において行動 a_i をとって状態遷移して目的を達成した場合、 r を報酬、 γ を減衰率、エピソード終了時点での行動回数を n とすると、 $i \in Z_n$ に対する重み $\omega(s_i, a_i)$ は次式にて更新される [3]。

$$\omega(s_i, a_i) \leftarrow \omega(s_i, a_i) + r \times \gamma^{n-i} \quad (1)$$

4 SMC による入力データの分割を用いた強化学習

強化学習によって得られる重みは K 個のサーバに分割して保存され、サーバ毎に分割された重み $\omega_j(s, a)$ の総和を取ることで元のデータとして扱うことができ、 $\omega(s_i, a_i) = \sum_{j=1}^K \omega_j(s_i, a_i)$ のように表される。これにより、いずれかのサーバからデータが漏洩した場合でも全体の機密性を保つことができる。本稿では、学習データの集合を分割する手法と、更新に用いる学習パラメータを分割する手法の 2 つについて考える。

4.1 経路の送信先変更によるデータ分割手法

学習によって得られるデータ集合を部分集合に分けて各サーバへ送信する。各サーバでの学習では、受け取ったデータ集合を用いて重みを式 (2) によって更新することで学習を行う。

$$\omega_j(s_i, a_i) \leftarrow \omega_j(s_i, a_i) + r \times \gamma^{n-i} \quad (2)$$

4.2 正規分布を用いた報酬の分割によるデータ分割手法

学習の際、重みの更新量を決定するパラメータである報酬の値を分割する。強化学習においては、データの数値自

体だけでなく大小関係などデータの傾向も重要な情報であるため、データ分割の割合決定に正規分布を用いることで各サーバ別に偏った学習を行わせる。各サーバでの学習では、報酬分割の割合 $\beta_j(s_i, a_i)$ と受け取ったデータ集合を用いて重みを式 (3) によって更新することで学習を行う。

$$\omega_j(s_i, a_i) \leftarrow \omega_j(s_i, a_i) + \beta_j(s_i, a_i) \times r \times \gamma^{n-i} \quad (3)$$

5 シミュレーション

本稿では数値実験として学習者がスタート地点からゴールまでの最短経路を学習する迷路問題を用いる。結果は従来手法、経路の送信先を変更する手法、正規分布によって報酬を分割する手法の 3 つについて比較検討する。実験環境として図 2 のベンチマーク問題として用いられる sutton の迷路を設定した。状態数 $|S| = 54$ 、行動数 $|A| = 4$ 、サーバ数 $K = 3$ 、最大学習回数 10000 回とし、20 回試行の平均値を学習結果とする。




図 2: sutton の迷路




図 3: 移動回数の推移

表 1: 学習後のテスト結果

	従来法		集合分割		報酬分割	
	成功	移動回数	成功	移動回数	成功	移動回数
統合	20	406.0	20	406.0	20	404.1
サーバ 1	-	-	20	2623.1	0	-
サーバ 2	-	-	20	26052.2	0	-
サーバ 3	-	-	20	731.4	0	-

図 3 は学習回数に対する目的達成までの移動回数を示しており、提案手法は従来手法とほぼ同等の性能を保てていることがわかる。また、表 1 は学習後の結果を固定し、図 2 の全ての地点を始点としたとき、全始点で目的を達成できた試行数、及びそのときの移動回数の総和を示している。提案手法については、各サーバのみの結果を用いた評価を同様に示した。これにより提案手法 (特に報酬分割手法) は、データの秘匿性を保持しつつ、従来法と同程度の結果を実現している。

6 まとめ

本稿では、強化学習の 1 つである PS 学習について 2 つのデータ分割手法を用いて SMC を実現し、その有効性を示した。今後の課題として、他のデータ分割手法の提案などによる更なる機密性の向上を行いたい。

参考文献

- [1] 宮西 他, 電子情報通信学会技術研究報告, Vol.114, No.49, P19-24 (2014)
- [2] H.Miyajima et al., Proc. of the IMECS, Vol 1, pp.381-386, 2016.
- [3] 木村 他, 計測と制御, Vol.38, No.10, pp.618-623, 計測自動制御学会 (1999)