

20

データを端末から漏洩させない分散深層学習

分散NW上で機械学習をするための非同期合意形成技術

どんな研究

現在の深層学習では、1か所に集約したデータを使ってモデルを学習することが一般的です。しかし、データ量の激増や**プライバシー保護**の観点から、近い将来データは**分散蓄積**されるようになるでしょう。多端末に分散蓄積された**データを外に出すことなく、機械学習モデルを最適化**する手法を提案します。

どこが凄い

多端末に蓄積されたデータは、**統計的に偏っている**と仮定することが自然です(例:各端末には一部クラスのデータしか存在しない)。その状況で、端末同士がモデル等の変数を**非同期に交換(通信)**しながら、全データを使って獲得したかのような**グローバルモデル**を学習するアルゴリズムを開発しました。


めざす未来

現在は、一部のアプリケーションプラットフォームがデータを集約/独占することにより、高度なサービスを提供しています。**データの所有権を個人に帰属**させ、プライバシーを保護しながら、多様なサービスに利用できる社会をめざしています。

目的・アプリケーション

背景: データ量、プライバシー保護、法的規制 (e.g. GDPR) の観点でデータを分散蓄積する時代になる。

目的: **分散蓄積されたデータを外に出すことなく、深層学習モデルを最適化**したい (ただし、モデルなどの変数を非同期で交換(通信)することは許容)。



問題の難しさ

難しいポイント: 各ノードにある**データが統計的に偏っている**とき、各ノードの評価関数を最小化するだけでは、**グローバルモデルは得られない**。

アプローチ: 全ノードの**モデルが一致する制約条件下で、評価関数**を最小化問題を解く。


$$\inf_{\{w_i | i \in V\}} \sum_{i \in V} F_i(w_i; x_i) \quad \text{合意形成}$$

$$\text{s.t. } A_{ij} w_i + A_{ji} w_j = 0 \quad A_{ij} = \begin{cases} \mathbf{I} & (i > j, j \in \mathcal{N}(i)) \\ -\mathbf{I} & (j > i, j \in \mathcal{N}(i)) \end{cases}$$

分散型深層学習: データ(x_i)がVノードに渡って分散蓄積している。最終的にノード間でモデルが一致する制約下(s.t.…)で、評価関数 $(\sum F_i)$ を最小化するようにモデル変数(w_i)を更新

非同期分散型深層学習アルゴリズム

提案方式: モデル主変数とラグランジュ双対変数をノード間で非同期に交換しながら、**グローバルモデル**を得るための学習アルゴリズムを構築 (任意のネットワーク構造で動作可)。





構築したアルゴリズム

Algorithm 1 PDMM SGD/ADMM SGD

```

1: Initialization of  $\lambda_i^{(0)}, w_i^{(0)}$ 
2: for  $k \in \{0, \dots, K-1\}$  do
3:   Step 1: Update model for each node
4:   for  $i \in V$  do
5:      $w_i^{k+1} \leftarrow (\mu w_i^k - \nabla F_i(w_i^k; x_i^{(i)})) / (\mu + \alpha |\mathcal{N}(i)| + \gamma |\mathcal{V}(i)|) + \sum_{j \in \mathcal{N}(i)} (\alpha A_{ij}^k \lambda_{ij}^k + \gamma w_j^k)$ 
6:   for  $j \in \mathcal{N}(i)$  do
7:      $\lambda_{ij}^{k+1} \leftarrow \lambda_{ij}^k - 2A_{ij} w_i^{k+1}$ 
8:   end for
9: end for
10: Step 2: Exchange and update variables at random time  $k$ 
11: for  $i \in V$  do
12:   Select  $j \in \mathcal{N}(i)$  at random
13:   Transmit  $\lambda_{ij}^{k+1} (w_j^{k+1}, \lambda_{ji}^{k+1})$ 
14:    $\begin{cases} \lambda_{ij}^{k+1} \leftarrow \lambda_{ij}^{k+1} & \text{(PDMM SGD)} \\ \lambda_{ij}^{k+1} \leftarrow \theta \lambda_{ij}^{k+1} + (1-\theta) \lambda_{ij}^k & \text{(ADMM SGD)} \end{cases}$ 
15: end for
16: end for
    
```



関連文献

[1] T. Sherson, R. Heusdens, B. Kleijn, "Derivation and analysis of the primal-dual method of multipliers based on monotone operator theory," *IEEE transactions on signal and information processing over networks*, Vol. 5, 2, pp. 334-347, 2018.
 [2] K. Niwa, N. Harada, G. Zhang, B. Kleijn, "Edge-consensus learning: deep learning on P2P networks with nonhomogeneous data," submitted to KDD 2020

連絡先

丹羽 健太 (Kenta Niwa) コミュニケーション科学基礎研究所 / メディアインテリジェンス研究所
 Email: cs-openhouse-ml@hco.ntt.co.jp

