

大規模分散処理フレームワーク Apache Spark を用いた 分散並列機械学習

加藤 香澄 (指導教員：小口 正人)

1 はじめに

近年カメラやセンサ等の発達やクラウドコンピューティングの普及により、一般家庭でのライフログの取得とそのデータの蓄積が可能になった。この技術は遠隔地から家庭にいるお年寄りや子供、ペットを見守ることができる安全サービスや、防犯対策・セキュリティといった用途に応用されている。しかし、サーバやストレージを一般家庭に設置して取得・蓄積した動画データの詳細解析をするのは困難なので、センサから取得した動画データはクラウドに送信して解析する必要がある。ここで、動画はデータサイズが大きいためセンサ・クラウド間の通信量が膨大になってしまう。また、クラウドは非常に多くの家庭からデータが送信されることが想定されているため、クラウドにて機械学習処理による動画データ解析を行うとその解析に要する計算量も膨大になるので、クラウドでの負荷が非常に大きくなる。従ってこの問題については、動画データの機械学習処理を並列化してクラウドの負荷を分散する必要がある。

本研究では、大規模データ分散処理プラットフォーム Apache Spark(以降、Spark と呼ぶ)[1] を用いてディープラーニングフレームワーク Chainer[2] による機械学習処理を並列化させることで、動画データ解析処理の効率化を図る。

2 関連技術

本研究ではクラスタでの負荷分散の基盤として Spark、動画データの解析処理に Chainer を用いる。以下に各ソフトウェアの概要を述べる。

2.1 Apache Spark

Spark は、高速かつ汎用的であることを目的に設計されたクラスタコンピューティングプラットフォームである。マイクロバッチ処理という極小単位でのバッチ処理を行うことが特徴で、他のビッグデータのツールと密接に組み合わせることができる。Spark 上では RDD(Resilient Distributed Dataset) にデータを保持し、用意されているメソッドを用いて操作することで自動的に分散が可能である。ポスト Hadoop として注目されている。

2.2 Chainer

Chainer はニューラルネットワークを実装するためのライブラリで、シンプルな記法によりネットワークを直観的に記述でき、畳み込みやリカレントなどの様々なニューラルネットワークにも対応可能なことが特徴である。このニューラルネットワークを多層にしたものはディープラーニングと呼ばれ、画像認識・自然言語処理・音声認識など様々な分野に応用されている。また、Chainer は CUDA をサポートしているため GPU による高速演算が可能であり、インストールも容易なので幅広く活用されている。

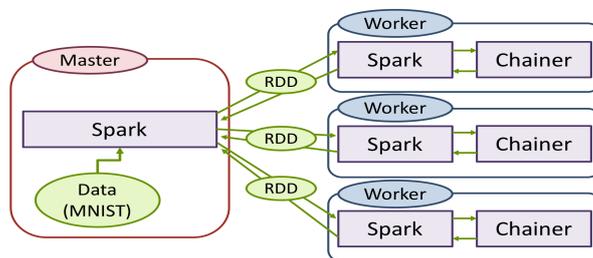


図 1: Spark と Chainer を用いたマスタ・ワーカ処理

表 1: 実験で用いた計算機の性能

OS	Ubuntu 16.04LTS
CPU	Intel(R) Xeon(R) CPU W5590 @3.33GHz (8 コア) × 2 ソケット
Memory	8Gbyte

3 実験

本実験には、0 から 9 の手書き数字の 28×28 画素の画像データに正解ラベルが与えられているデータセットである MNIST[3] を用いる。マスタで Python のプログラムを実行することにより、MNIST を Spark に読み込ませて RDD に変換し、変換した RDD を各ワークに Spark の分散機能を用いて分配し、ワークにおいて Chainer を用いて画像データの評価をする実験を行う(図 1)。

3.1 実験概要

実験では、マスタ 1 台とワークとして最大 5 台の端末を Spark Standalone Mode で接続し、マスタでプログラムが実行され、各ワークでのタスクが完了してワークからマスタに結果が返って出力されるまでに要する時間を測定した。本実験では、以下 2 つのパラメータを変えて測定した。

1. Spark に読み込ませるデータの partition 数
2. ワークのノード数

また、この実験を元にタスクがどのように各ノードに分配されているのかを観測した。

実験で用いた計算機の性能を表 1 に示す。マスタ及び全ワークには同質のノードを用いており、図 2 に示すクラスタ構成とした。



図 2: 実験環境

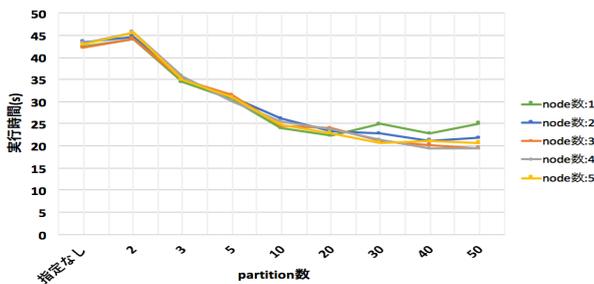


図 3: partition 数及びノード数の変化による実行時間

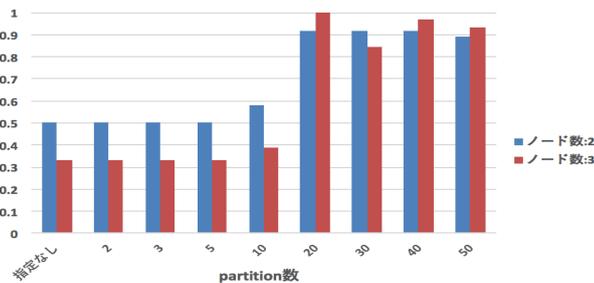


図 4: Fairness Index

3.2 実験結果

実行時間の測定結果を図 3 に示す。このグラフは、ノード数を 1～5 まで変化させ、partition 数を指定なし、2,3,5,10,20,30,40,50 と変化させた際の測定結果 10 回の平均値を用いて作成している。この実験で partition 数が指定なしの場合には、デフォルトで Spark によって partition 数が 2 に設定されている。実験の結果、partition 数が増加すると実行時間が約 1/2 ほどまで減少することがわかった。また、partition 数の増加による実行時間の減少は partition 数 40 ほどで横ばいになった。一方、ノード数の増加による実行時間の減少はわずかであり、効率よく分散処理が行えていないことがわかった。

図 4 に、ノード数が 2 と 3 の場合についてタスクがどのように各ノードに分配されているのかを観測した結果を、公平性を示す指標である Fairness Index[4] で示す。Fairness Index は以下の式で計算でき、値が 1 に近いほど公平性が高いことを示す。

$$FairnessIndex : f_i = \frac{(\sum_{i=1}^k x_i)^2}{k \sum_{i=1}^k x_i^2}$$

結果から、実行時間に減少が見られた場合でも実際にはタスクが偏って分配されてしまっていたことが判明した。グラフより、partition 数 10 から 20 の間で公平性に大きな変化が見られたため、partition 数 20 までの Fairness Index 及び実行時間変化を図 5 に、ノードに割り当てられた最多タスク数及び実行時間変化を図 6 に示す。図 5 から、公平性と実行時間は必ずしも反比例にならないことがわかった。図 6 からは、ノードに割り当てられた最多タスク数はノード数が 2 と 3 の場合でほぼ同じになっていること、実行時間変化は最多タスク割り当てによる律速の影響をほとんど受けていないことがわかった。

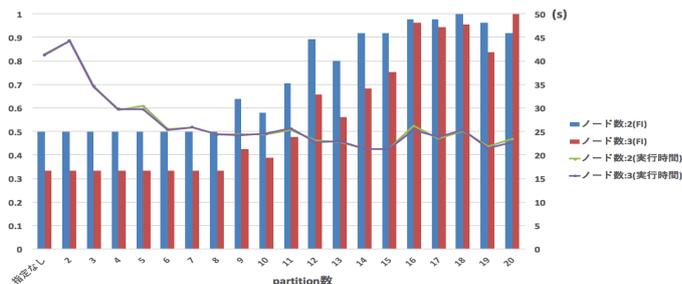


図 5: Fairness Index と実行時間変化

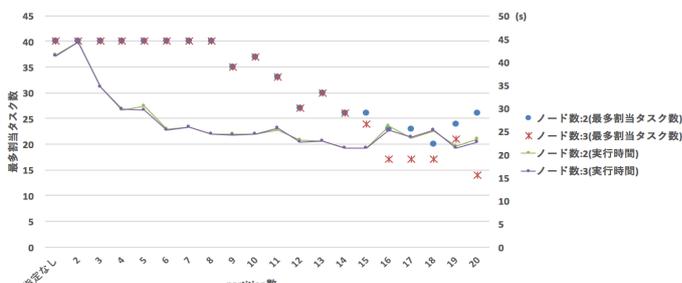


図 6: 最多割当タスク数と実行時間変化

4 まとめ

Chainer による解析処理を Spark で並列化し、負荷分散を行った。実行時間とタスク割り当てに関して実験し、ノード数増加による実行時間の減少はわずかであること、タスク割り当ての公平性と実行時間が反比例しないこと、実行時間変化が最多タスク割当数による律速の影響をほとんど受けていないことが判明した。

今後の課題として、振舞いの実態を詳しく調査していくことにより現時点での並列処理の課題を明らかにし、処理の効率化を図っていきたい。

謝辞

この成果の一部は、JSPS 科研費 JP16K00177 および国立研究開発法人新エネルギー・産業技術総合開発機構 (NEDO) の委託業務の結果得られたものです。

参考文献

- [1] Apache Spark, <https://spark.apache.org/>.
- [2] Tokui, S., Oono, K., Hido, S. and Clayton, J.: Chainer: a Next-Generation Open Source Framework for Deep Learning, In Proceedings of Workshop on Machine Learning Systems (LearningSys) in The Twenty-ninth Annual Conference on Neural Information Processing Systems (NIPS) (2015). 6 pages.
- [3] Lecun, Y., Cortes, C. and Burges, C. J.: The MNIST Database of handwritten digits, <http://yann.lecun.com/exdb/mnist/>.
- [4] Chiu, D.-M. and Jain, R.: Analysis of the increase and decrease algorithms for congestion avoidance in computer networks, Computer Networks and ISDN Systems, vol. 17, pp. 1-14 (1989).