

Apache Sparkによるディープラーニングの分散処理

1815008 安藤 祐斗




図 1: ディープラーニングの例（歩行者探知）

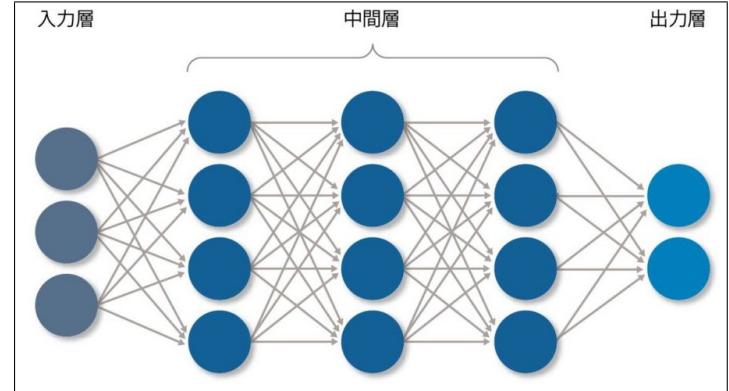


図 3: ニューラルネットワーク

ニューラルネットワークを用いた手法をディープラーニングと呼ぶ。中間層を多く用いることによってより複雑な分析ができる、データの特徴を抽出することができる。

4. ディープラーニングを分散処理させるライブラリ

本研究では、ディープラーニングの分散処理化ライブラリの一つである、BIGDL を使用する。

5. 実験結果ならびに考察

6. 進捗状況と課題 現在、BIGDL と Spark のダウンロード、インストールとクラスタの環境構築を 3 台の PC で行っている。2 台以上でプログラムを実行する際にエラーが発生しているため、解決を急ぐ。また、DeepLearningforjava といった他のライブラリもできたら試すことと、発展してどんなことができるかを考える。

参考文献

1. はじめに

機械学習の手法の一つであるディープラーニングは、近年の進歩により、画像認識などにおいての認識精度の向上、自動運転、医療研究などの幅広い分野での活用がされている。図 1 はディープラーニングの例のひとつである。

本研究では、Apache Spark の並列分散処理機能を使いディープラーニングを実行する。次に、この二つの組み合わせによって得られる優位性や、既存のプログラムにはない新規性を確認する。

2. Apache Sparkによる並列分散処理

Apache Spark とは大量のデータを複数のコンピュータで処理を行う、並列分散処理を可能としたソフトウェアである。HDFS (Hadoop Distributed File System) と呼ばれる複数のサーバーでデータを格納するファイルシステムと、格納されたデータを繰り返し加工し処理する RDD という分散データセットによって構成されている。図 2 に主な Spark の構成を示す。

3. ニューラルネットワークとディープラーニング

ニューラルネットワークとは、神経細胞（ニューロン）と神経回路網（シナプス）で構成された、人間の脳神経を模倣した数理モデルである。ニューラルネットワークは入力層、中間層、出力層の 3 つの層に分けられ、この中のさまざまな計算を行う中間層が、図 3 のように 3 層以上の



図 2: Spark の構成