

Zinraiディープラーニングが提供する 深層学習システム開発環境

Deep Learning System Development Platform Provided by Zinrai Deep Learning

● 藤井 崇志 ● 佐々木 卓 ● 吉田 裕之

あらまし

AI(人工知能)の分野で中心的な技術となったDeep Learning(深層学習)は、ニューラルネットワークを多層にしたものであり、従来技術より認識精度が高く、研究開発のみならずビジネスへの活用も期待されている。一方で、高い認識精度を得るためには、学習に用いる大量の教師データを準備し、ニューラルネットワークなどを選択した上で、利用者自身が様々なパラメーターをチューニングしながら何度も学習させる必要がある。更に、この学習には高速演算可能な計算リソース(GPU: Graphic Processing Unit)を確保する必要もある。富士通では、これらの課題を解決するための深層学習システム開発環境「Zinraiディープラーニング」を2017年4月から提供している。

本稿では、Zinraiディープラーニングがどのように上記の課題を解決しているかについて述べる。

Abstract

Deep learning, the pivotal technology in AI (artificial intelligence), is based on multi-layered neural networks. It has enhanced the recognition capabilities of conventional technologies, and it is highly expected that the technology may be applied not only to the research and development field but also to business. To attain a high degree of reliable recognition, it is necessary to involve a large amount of learning data and select appropriate neural networks. The user must adjust a variety of parameters and repeat learning procedures. Furthermore, this learning process requires high-speed computational resources (graphic processing unit: GPU). To address these challenges, Fujitsu has offered Zinrai Deep Learning, a platform for developing deep learning systems, since April 2017. This paper explains how Zinrai Deep Learning tackles and resolves these challenges.

まえがき

AI（人工知能）の分野で中心的な技術となったDeep Learning（深層学習）は、多層のニューラルネットワーク（以下、NN）を用いた機械学習手法である。

近年、Deep Learningが注目されるようになったのは、2012年に開催された画像認識コンテストILSVRC（ImageNet Large Scale Visual Recognition Challenge）において、トロント大学のSuperVisionチームがDeep Learningを用いた手法で、誤認識率を過去最高であった25.7%から15.3%へと大幅に低減し、優勝を飾ったことに起因する。また同年6月には、Googleが事前の学習なしで猫の写真を認識する手法を発表した⁽¹⁾。その後、画像認識の分野ではDeep Learningを用いた手法が一般的となり、2015年には人間による誤認識率（およそ5%）以下になったため、「機械は目を持った」と言われるようになった。Deep Learningの需要は画像認識だけにとどまらず、2016年10月にGoogleが発表した自然言語翻訳処理への適用など、幅広い分野で実用化の実績が出てきた。

Deep Learningを利用する際には、大きく二つのフェーズがある。一つは教師データによる学習フェーズであり、もう一つは学習結果を用いた推論フェーズである。両フェーズは必要な計算リソースが大幅に異なり、学習フェーズに圧倒的に多くの計算リソースが必要になる。また、学習フェーズにおいては、ネットワークモデルごとにハイパー

パラメーターの設定が必要となる。ハイパーパラメーターとは、機械学習では自動的に決められるものではなく、学習する前にあらかじめ人間が決めておかねばならないパラメーターである。高い認識率を得るためには、試行錯誤によるハイパーパラメーターの調整が不可欠である。

富士通と富士通研究所は、2016年9月にDeep Learningのための高速化技術に関して、OSS（Open Source Software）として提供されているDeep Learning用フレームワークCaffeを利用して学習時間を大幅に短縮する分散学習手法（Distributed Caffe）を発表した⁽²⁾。また、高い認識率を得るためにハイパーパラメーターを自動調整するNN最適化技術も開発した。更に2017年4月から、これらの技術とDeep Learning開発のその他の課題を解決する技術を盛り込んだ、深層学習システム開発環境「Zinraiディープラーニング」をクラウドサービスとして提供している。

本稿では、Deep Learningの学習フェーズにおける課題に着目し、Zinraiディープラーニングがそれらをいかに解決しているかを紹介する。

Deep Learning開発の課題

Deep Learningの利用が一般化するにつれて、その開発上の課題が明らかになってきた。Deep Learningの学習は、図-1に示すように五つのステップに分かれている。本章では、その流れと各ステップにおける課題を説明する。




図-1 Deep Learningによる学習ステップ

● 事前準備(課題1)

Deep Learningの開発を始めるには、認識対象を決める必要がある。その後、認識率などの目標値の設定を行い、それに対して必要な教師データを確保する。また、Deep Learningは学習を繰り返し実行するため、多くの演算時間を要する。演算時間を短縮するためには、高速演算可能なGPU (Graphic Processing Unit) などの計算リソースを確保する必要がある。

次に、利用するフレームワークを選定する。フレームワークは、Caffe, Caffe2, TensorFlow, Chainer, MXNetなど、多くの選択肢が存在するため、選定に当たって利用者はそれぞれの特徴を知っておく必要がある。例えば、CaffeはDeep Learningのネットワーク構造を宣言的に記述でき、プログラムを記述する必要がないため、Deep Learningの知識さえあれば容易に利用できる。一方、TensorFlowやMXNetなどのフレームワークはプログラムで記述するため、プログラミングの知識が必要になる。このように、フレームワークを選定するために様々な知識が必要になる。

また、Deep LearningでGPUを利用した高速演算を行うために、GPUの提供元であるNVIDIA社はCUDAやcuDNNなどのライブラリを提供している。このライブラリとフレームワークには版数の依存関係があり、その組み合わせを考慮した設定を行わなければならない。このように、まず学習を始める前にフレームワークの選定と設定が必要となる。

● 学習データセットの準備(課題2)

Deep Learningでは、教師データとなるデータセットの質が学習精度に大きく影響する。

Deep Learningにおいて、学習データセットの収集は最もコストがかかる工程である。例えば、車の自動走行用の教師データであれば、事故シーンや人・物が飛び出してくるシーンなどが特に重要となるが、これらのデータは入手が非常に難しい。

また、こうして入手した教師データに対して、解像度や色などの形式に統一し、更に作成したデータセットから訓練用・検証用・テスト用にデータを分割するなど、非常に多くの工数がかかる。

● ネットワーク構造の設計(課題3)

このステップでは、ネットワークモデルの選択

と、ハイパーパラメーターの設定を行う。ネットワークのモデルとして、GoogLeNetやAlexNetなどの実績のあるモデルを選定することが多いが、学習させたい対象によっては自らモデルを作成する必要がある。

モデル選定後、ハイパーパラメーターの設定を検討する。ハイパーパラメーターの例としては、学習率、重み、バッチ数、ネットワーク層のニューロン数などがある。最適なハイパーパラメーターを決定するには、経験に基づく試行錯誤を伴うため、非常にコストがかかる作業となっている。

● 学習(課題4)

ここまでの手順を経て、訓練用データを用いたDeep Learningの学習に入る。学習させるデータ量やネットワークモデルによって学習時間は大きく異なり、例えば前述したILSVRCの教師データ(1 Tバイト)を用いて高い認識精度を出すためには、数日の学習時間を要する。

また、実際の学習作業では、初期段階で小規模なデータに対して様々なハイパーパラメーターでの学習を複数回実行し、良好な学習結果が得られそうなハイパーパラメーターを抽出する。その後、大量のデータを用いて大規模な学習を行うが、その際には膨大な演算量が必要となる。このように、学習計画や段階に応じて必要となる計算リソースの量が異なるケースがある。

● 評価(課題5)

学習が完了した後、学習に用いられなかったデータ(検証用・テスト用データ)を使って、得られたモデルの認識精度を評価する。学習に用いた訓練用データでは、目標の認識精度を満たしていても検証用データでは目標値にたどり着かない場合があり、これを過学習と呼ぶ。その場合は、ネットワーク選定やハイパーパラメーター調整に戻り、学習を繰り返す必要がある。

繰り返し学習を行う上では、学習に用いたデータセットとネットワークをどう組み合わせたのか、その結果がどうであったのかを管理することが重要になる。何度もハイパーパラメーターの調整を繰り返す場合は、どのハイパーパラメーターを変更したことによって結果がどのように変わったのかを管理することが煩雑になってしまう。

Zinraiディープラーニングが提供する価値

前章では、Deep Learningの事前準備から評価に至る流れと課題を明らかにし、学習は数々の試行錯誤が必要なスキームとなっていることを述べた。本章では、各ステップの課題をZinraiディープラーニングがいかに解決していくかについて述べる。

● 事前準備の負荷を低減する検証済環境

Zinraiディープラーニングでは、バッチ型と対話型の二つの学習環境を提供している。

バッチ型では、ハイパーパラメーターを入力するだけで簡単に学習できるGUIの学習環境を提供している。対話型では、CLI（Command Line Interface）でユーザーがプラットフォームとしてGPUを自由に使える学習環境を提供している。また、フレームワークはバッチ型学習についてはCaffeを提供している。対話型学習では、ユーザーが独自にフレームワークを導入できるが、Caffe, TensorFlow, Chainerについては事前検証した環境も提供している（課題1の解決）。事前検証した環境では、GPUを利用するためのライブラリ（CUDA, cuDNN）との組み合わせを検証済みであるため、ユーザーはフレームワークおよびライブラリをすぐに利用できる。

● 学習を支援するGUI

Zinraiディープラーニングのバッチ型学習環境では、ダッシュボード、データセット作成、ネットワークモデルの設定、ハイパーパラメーターの設定の各機能をGUIで提供している。

ダッシュボードは、Caffeの学習状況（epoch数の進捗状況）が一目で分かる機能を提供し、画面上で容易に確認できる（図-2）。

データセット作成では、教師データの選択、画像サイズ、画像形式を入力することでデータセットを容易に作成できる（課題2の解決）。

● ネットワーク構造設定と最適化

ネットワークモデルの設定は、Zinraiディープラーニングで提供している三つの基本的なネットワークモデル（LeNet, AlexNet, GoogLeNet）から選択できる。加えて、より高い精度を得るために、ネットワークモデルをユーザー自身でも記述できる。

ハイパーパラメーターはGUIで入力できる。前述したように、これまでハイパーパラメーターは経験則もしくは試行錯誤を繰り返すことでしか高い精度を得るための最適値を見つけられなかった。一方、Zinraiディープラーニングでは、ハイパーパラメーターのうち、ネットワークモデル各層のニューロン数を自動調整するNN最適化技術を提供している（図-3）。これによって、経験の少ないユーザーであっても短時間で最適値を求められるように支援する（課題3の解決）。

● 柔軟に利用可能なGPUインフラ

前述したとおり、Deep Learningで高い認識精度を得るためには、数日から場合によっては数週間を要することもある。Zinraiディープラーニングでは、学習時間の短縮を目的としてGPU（NVIDIA Tesla P100）による演算処理をクラウドサービス



図-2 ダッシュボードによる学習状況の可視化




図-3 NN最適化によるハイパーパラメーターの調整

として提供しており、ユーザーの学習計画や段階に応じて必要なGPU数を選択することによって、最適な演算能力が得られる（課題4の解決）。

● ワーキングセットによる学習結果の一元管理

Zinraiディープラーニングでは、学習をワーキングセットという単位で管理している。ワーキングセットは、学習に用いたデータセットと学習済ネットワークモデル、および学習時のハイパーパラメーターを一元管理でき、この組み合わせと結果のタスク管理が容易である。

これにより、一部のハイパーパラメーターを調整しながら学習を繰り返す場合や、以前に作成したワーキングセットに新たな学習データを加えて追加学習し、学習済みモデルの汎用性を高める場合においてもタスク管理の煩雑さを解消できる（課題5の解決）。

成長するAI

ここまでは、Zinraiディープラーニングの学習機能について説明した。Deep Learningを商用利用するためには、学習環境に加えて推論環境の拡充が重要となる。このため、Zinraiディープラーニングはエッジデバイス^(注1)上での推論環境を提供している。

(注1) 別々のネットワーク間で通信を行い、データのやり取りが可能な機器の総称。

2018年7月時点では、エッジデバイスで推論アプリケーションを構築するためのSDK（Software Development Kit）をiOS、Androidを対象として公開している。このSDKを用いて開発されたアプリケーションは、Zinraiディープラーニング上の学習済みモデルをダウンロードでき、それを利用した推論が可能である。推論した結果をエッジデバイスに保存し、Zinraiディープラーニングにアップロードすることで教師データとして利用できる。この教師データと既存の教師データを合わせて、追加学習が可能である。

このように、学習、ダウンロード、推論、アップロード、追加学習を繰り返すことで、より高い精度のモデルを持続的に運用し、成長するAIを実現できる（図-4）。

Zinraiディープラーニングの展開

Zinraiディープラーニングは、2017年4月にクラウドサービスとオンプレミスで同時にリリースした。これまで、多くのお客様にご利用いただき、以下のようなご意見が寄せられている。

(1) 環境準備

Deep Learningフレームワークのインストールや準備は非常に手間がかかるが、検証済みの環境をクラウドサービスで提供しており、準備が不要なため非常に早く利用が開始できる。




図-4 Zinraiディープラーニングとエッジデバイスの連携

(2) データの加工

通常、教師データはDeep Learningのネットワークモデルごとにサイズ変更が必要であり、そのためプログラミングが要求された。Zinraiディープラーニングでは、画像のサイズ変更や分割が非常に簡単にGUIで行える。

(3) ハイパーパラメーター

ハイパーパラメーターチューニングは、通常プログラミングが必要であるが、GUIで簡単に設定できる。

(4) 学習の実装・モデルおよび結果の可視化

ダッシュボードやモデル表示で簡単にデータを可視化できる。

む す び

本稿では、Deep Learningの学習における課題と、それらの解決手法としてZinraiディープラーニングの有効性について述べた。

富士通では、Zinraiディープラーニングを更に速く・便利に・使いやすくするエンハンスを行う予定である。また、スーパーコンピュータ「京」^(注2)の開発技術と、Deep Learningの知識を多く取り込んだ専用のプロセッサDLU (Deep Learning Unit)

(注2) 理化学研究所と富士通が共同開発したスーパーコンピュータ。「京」は理化学研究所の登録商標。

を提供していく。

参考文献

- (1) 日経XTECH：Google、大規模人工ニューロンネットワークを用いた研究成果を紹介。
<http://tech.nikkeibp.co.jp/it/article/NEWS/20120627/405501/>
- (2) 池 敦ほか：Deep Learningのための高効率化技術。
FUJITSU, Vol.68, No.5, p.15-21 (2017).
<http://www.fujitsu.com/jp/documents/about/resources/publications/magazine/backnumber/vol68-5/paper03.pdf>

著者紹介



藤井 崇志 (ふじい たかし)

富士通（株）
AIサービス事業本部
AI基盤事業の立ち上げおよびクラウド
システムの開発・運用に従事。



佐々木 卓 (ささき たく)

富士通（株）
AIサービス事業本部
AI基盤事業の立ち上げおよびクラウド・オンプレミスのシステムアーキテクトとして、基礎設計に従事。



吉田 裕之 (よしだ ひろゆき)

富士通（株）
AIサービス事業本部
ディープラーニングや量子コンピューティングなどのAI基盤技術の社内外へ提供推進に従事。