

深層強化学習におけるボトムアップなモデル構築と 学習精度予測回帰式を用いた Neural Architecture Search

Neural Architecture Search using Bottom-Up Model Construction and Prediction of Learning Accuracy using Regression in Deep Reinforcement Learning

遠田 海生¹⁾ 代 美月¹⁾ 神野 健哉¹⁾
Minaki Enta Miduki Dai Kenya Jin'no

概要

近年、畳み込みニューラルネットワーク (CNN) が広く利用されているが、CNN の性能はその構造によって大きく異なる。具体的な理論的な設計手法は確立されていないが、2017 年に Google が強化学習による Neural Architecture Search[1] を導入し、特定のタスクに合わせたニューラルネットワーク構造を自動的に探索・最適化できる手法として注目を集めた。しかしこの手法は一度の施行でモデル全体を推測するために、多大なリソースと計算能力が必要になるという欠点がある。そこで本稿では、DQN を用いたボトムアップなモデル構築手法と、学習精度予測回帰式による計算時間短縮の効果を検証する。

1 はじめに

先行研究 [1] では、RNN を用いた強化学習エージェントで学習が行われているが、この手法は計算量が膨大であり、一度にモデル全体を推測するためには各層の関係を正確に評価することが難しい。本研究では DQN[2] を用いて一層ごとに層を推測し追加をするボトムアップアプローチを採用し、モデル構築の精度向上と計算効率の改善を図った。また、学習速度向上のために、モデルの精度予測の回帰式を導入し、さらなる計算時間の短縮を試みた。

2 モデル構築手法

本研究では DQN[2] を用いて CNN の構造探索を行う。DQN の各ステップではエージェントが層を「追加する」か「追加しない」を選択する。「追加する」の場合、層の種類を選択した上で追加し、「追加しない」の場合はそれ以上層を追加しない。このプロセスを行動とし、最大 28 回繰り返す。表 1 に示すように、追加する層の種類を予め定義し、Conv2D() が選択された場合には表 2 に示すパラメータから選択する。エージェントがこれらを正しく判断し、学習ができるように、2つのエージェントを用いる。Conv2D 層以外の層でパラメータの選択を行わ

ない理由は、BatchNormalization() や Activation('relu') はパラメータ指定が不要であり、その他の層は連続して重ねることで疑似的に別のパラメータの層と近似することができるためである。その後、DQN によって構築されたモデルに GlobalAveragePooling 層と Dense 層を追加し、画像分類タスクを実行できる CNN モデルを作成する。よって、CNN モデルは最大 30 層で構築される。

表 1 追加する層の種類

Conv2D()
Maxpooling(pool.size=(2,2))
Dropout(0.25)
BatchNormalization()
Activation('relu')
追加しない

表 2 畳み込み層のパラメータ選択

Conv2D(32,(3,3),padding="same")
Conv2D(64,(3,3),padding="same")
Conv2D(128,(3,3),padding="same")
Conv2D(256,(3,3),padding="same")
Conv2D(512,(3,3),padding="same")

3 精度予測

文献 [3] では、150 エポック目の画像分類精度を予測するために、トレーニングの最初の 5 エポックから抽出された 3つの説明変数を用いる式 (1) に示す回帰式を提案している。本研究でも、この回帰式を採用し、DQN による層構築の過程で、学習精度を効率的に予測し計算時間を短縮することを目指す。

$$\begin{aligned}(\text{pred_acc}) = & 2.277 \cdot (\text{Difference}) - 5.331 \cdot (\text{Slope}) \\ & + 2.263 \cdot (\text{val_acc}) + 0.3743\end{aligned}\quad (1)$$

ここで、「Difference」は 5 エポック目のトレーニング精度とテスト精度の差異を意味し、「Slope」は 3 エポック目のトレーニングデータ精度を 3 で割った精度の初期変化率を意味し、「val_acc」は 5 エポック目のテストデータの実際の分類精度を意味し、「pred_acc」は予測精度を意味する。

1) 東京都市大学大学院総合理工学研究科情報専攻
Informatics, Graduate School of Integrative Science and
Engineering, Tokyo City University

4 実験 1

本手法を用いて強化学習の学習回数を 200,000 ステップとし、生成された CNN モデルで CIFAR-10 分類問題を 15 エポック学習したときの分類精度を各エージェントの報酬とした。最も高評価であったモデルを表 3 に示す。このモデルで 150 エポック学習した結果、分類精度は 89.24%に達し、高性能なモデルを探索できたことを示している。

表 3 実験 1 で出力された CNN モデル

Conv2D(512,(3,3),padding="same")
Conv2D(64,(3,3),padding="same")
BatchNormalization()
Conv2D(64,(3,3),padding="same")
Activation('relu')
Maxpooling(pool_size=(2,2))
BatchNormalization()
Conv2D(256,(3,3),padding="same")
Dropout(0.25)
Activation('relu')
Conv2D(512,(3,3),padding="same")
Dropout(0.25)
Conv2D(512,(3,3),padding="same")
Dropout(0.25)
Dropout(0.25)
Activation('relu')
BatchNormalization()
Conv2D(512,(3,3),padding="same")
Activation('relu')
Conv2D(256,(3,3),padding="same")
Dropout(0.25)
Dropout(0.25)
BatchNormalization()
GlobalAveragePooling2D()
Dense(10)

5 実験 2

実験 2 では、式 1 に示した回帰式 [3] を用いて 5 エポック目までの説明変数から 150 エポックでの分類精度を予測し、これを報酬として学習を行った。その結果導出された最も高評価であったモデルを表 4 に示す。このモデルで 150 エポック学習した結果、分類精度は 88.09%であり、表 5 に示したように、実験 1 と比べ精度は 1%低下したが、計算時間は 33.2%削減できた。

表 4 実験 2 で出力された CNN モデル

Conv2D(512,(3,3),padding="same")
BatchNormalization()
Conv2D(256,(3,3),padding="same")
Conv2D(256,(3,3),padding="same")
Maxpooling(pool_size=(2,2))
Conv2D(256,(3,3),padding="same")
BatchNormalization()
Conv2D(256,(3,3),padding="same")
Dropout(0.25)
Activation('relu')
Conv2D(192,(3,3),padding="same")
Conv2D(192,(3,3),padding="same")
Activation('relu')
Dropout(0.25)
Conv2D(512,(3,3),padding="same")
Dropout(0.25)
Activation('relu')
Dropout(0.25)
BatchNormalization()
Activation('relu')
GlobalAveragePooling2D()
Dense(10)

表 5 実験 1,2 の比較

	実験 1	実験 2
精度	89.24%	88.09%
1step(s/step)	18.83(s/step)	12.56(s/step)
200000step(s)	3,765,962(s)	2,512,571(s)
日数	43.59 日	29.08 日

6 まとめ

本稿では、DQN を用いた CNN の構造探索手法を提案し、学習精度予測回帰式による計算時間の短縮を試みた。その結果、高精度なモデルを効率的に構築できることを確認した。今後の課題として、さらに大規模なデータセットでの評価や他の強化学習手法との比較を進める予定である。

謝辞

本研究の一部は JSPS 科研費 23K11266, 23H03387, 24K15115, 東北大学電気通信研究所共同プロジェクト研究, 東京都市大学重点推進研究未来知能ユニットの助成によるものです。

参考文献

- [1] Barret Zoph, Quoc V. Le, "Neural Architecture Search with Reinforcement Learning", ICLR 2017.
- [2] Vlad Mnih, Koray Kavukcuoglu, David Silver, Alexander Graves, Ioannis Antonoglou, Daan Wierstra, Martin Riedmiller, "Playing Atari with Deep Reinforcement Learning," Proc. NIPS Deep Learning Workshop 2013.
- [3] Mizuki Dai, Kenya Jin'no, "Predicting Classification Performance of Convolutional Neural Networks", NOLTA, IEICE 2023.