

重回帰分析による学習初期状態を活用した画像分類予測

Image classification prediction utilizing the early state of learning by multiple regression analysis

代 美月¹⁾ 神野 健哉¹⁾
Mizuki Dai Kenya Jin'no

概要

CNN の構築ではハイパーパラメータを変化させ、多くの実験結果から知見を得る。そのため、多くの実験時間を必要とする。もし、学習初期の状態から最終学習回数での分類精度の予測が可能であれば実験時間が短縮され、より短い時間で CNN が構築できるのではないかと考えた。そこで本研究は CNN の最終学習回数のテスト分類精度を学習初期の状態を使って予測することを目的とする。その結果、低い誤差で最終学習回数での分類精度を予測できることを確認した。

1 はじめに

CNN をはじめとする機械学習モデルはデータセットごとに構造を変えるべきであると考えられる。人間の脳みそが全て一緒ではないのと同じように仕事や趣味に合わせた脳構造を今までの経験を使って形成していく。一つのデータセットに対する CNN の構築ではハイパーパラメータを変化させ、多くの実験結果から知見（経験）を得る。その知見を利用しさらに高い精度になるであろうモデルを構築する。モデル構築に際してこの多くの試行回数を減らすことは難しいと考える。もし、学習初期の状態から最終学習回数での分類精度の予測が可能であれば実験時間が短縮され、より短い時間で CNN の構築が可能となる。そこで本研究は CNN の最終学習回数のテスト分類精度を学習初期の状態を使って予測することを目的とする。学習回数 5 回の学習初期の状態から学習回数 150 回での分類精度の予測を行う。我々が経験則から得た学習初期の特徴を説明変数とし、最終学習回数のテスト分類精度を目的変数とする。本研究で使用する回帰は、重回帰、多項式回帰、XGBoost[1] を用いて比較検討を行う。

2 回帰方法

予測するために必要な学習初期で得られる 3 項目を説明変数として、最終学習回数での分類精度を目的変数とする。我々の経験則から得られた [2]

- トレーニングデータ正答率の傾き
- テストデータ正答率の上昇度
- 学習初期の実際の精度

1) 東京都市大学大学院総合理工学研究科情報専攻

これら 3 つを説明変数とし学習回数 150 回の時のテスト精度を目的変数とした重回帰分析、多項式回帰、XGBoost によって予測値を求めた。説明変数にモデル構造のハイパーパラメータを使用しないため、モデル構造に依存しない予測を目指している。

3 データセット

本研究では画像分類タスクを対象としてモデルの精度を評価する。画像分類用データセットには CIFAR-10[3] を用いた。32×32 の画像サイズ、10 種類のクラスラベルが付与されている。トレーニング画像 50,000 枚、テスト画像 10,000 枚で構成される。我々は 202 種類の CNN モデルを構築し、1 モデルに対して初期値の乱数を変えて 3 回実行した。3 回の学習曲線は全て同じにはならない。本研究では学習曲線の値のみを用いるため、乱数を変更した 3 種類のモデルを違うモデルとみなす。よって合計 606 モデルをモデルデータセットとし、回帰アルゴリズムによって予測値を求める。モデルの一部を表 1 に示す。

表 1 使用したモデル

No.	Conv2D	Dense	MaxPool	BatchNorm	Batchsize	Dropout	Drop rate	Params
1	6	2	4	6	250	0	0.0	1,314,316
2	3	2	2	3	100	3	0.2	481,548
3	6	2	4	0	100	6	0.1	1,310,976
4	3	2	2	3	500	3	0.4	481,548
5	3	2	2	3	250	3	0.2	241,804
6	6	2	4	6	250	6	0.7	7,295,500
7	6	2	4	6	500	6	0.1	1,211,788
8	3	2	2	3	500	3	0.4	241,804
9	6	2	4	6	500	6	0.4	7,295,500
10	3	2	2	3	100	3	0.6	241,804
11	6	2	4	0	200	6	0.6	1,310,976
12	3	2	2	3	250	3	0.6	481,548
13	6	2	4	6	100	6	0.3	1,211,788
14	3	2	2	0	100	3	0.8	241,024
15	6	2	4	6	100	6	0.1	1,211,788

4 予測結果

最終学習回数の分類精度と各回帰の予測値を比較した表を表 2、表 3、表 4 に示す。これらは各行がモデル番号を表しており、各列が左から、求めた予測値、最終学習回数の分類精度、求めた予測値と最終学習回数の分類精度の誤差を表している。求めた予測値と最終学習回数の

分類精度の誤差を RMSE で評価した。この RMSE は 606 モデル全てに対する誤差から算出した。その結果 RMSE は、重回帰分析で 6.48、多項式回帰で 4.55、XGBoost で 4.19 という結果が得られた。十分な予測が可能であることから、説明変数とした 3 項目で分類精度の予測は十分に行えると言える。

表 2 重回帰による予測値

No.	重回帰分析による予測値(%)	学習回数150回の分類精度(%)	誤差(%)
1	76.84	78.37	-1.53
2	94.44	83.26	11.18
3	93.30	83.07	10.23
4	64.80	64.37	0.43
5	89.19	88.87	0.32
6	76.12	81.65	-5.53
7	79.60	81.59	-1.99
8	92.89	85.37	7.52
9	80.36	82.76	-2.40
10	80.02	78.96	1.06
11	75.28	82.33	-7.05
12	91.13	82.63	8.50
13	79.14	77.40	1.74
14	46.08	23.82	22.26
15	76.96	75.58	1.38

表 3 多項式回帰による予測値

No.	多項式回帰による予測値(%)	学習回数150回の分類精度(%)	誤差(%)
1	81.25	78.37	2.88
2	83.48	83.26	0.22
3	86.87	83.07	3.80
4	65.82	64.37	1.45
5	88.85	88.87	-0.02
6	80.17	81.65	-1.48
7	81.87	81.59	0.28
8	84.89	85.37	-0.48
9	84.79	82.76	2.03
10	84.03	78.96	5.07
11	82.31	82.33	-0.02
12	87.96	82.63	5.33
13	79.28	77.40	1.88
14	32.01	23.82	8.19
15	81.51	75.58	5.93

5 考察

これら 3 つの結果で共通して誤差が 10% 以上あったモデルが存在した。それらのモデル学習時の学習曲線を図 1 に示す。我々の知見では、説明変数の傾きが大きく差が小さいモデルの性能が一番高く、両方欠けたモデルの性能が一番劣っていると考える。(a) では、学習回数 150 回の分類精度は 82.63% であったのに対し全ての回帰アルゴリズムでの予測値がこれよりも高い値になった。これは傾きは大きい差も大きいことに起因していると考えられるが、これらの回帰では差の値を重要視できていないのではないかと考える。(b) では学習回数 150 回の分類精度は 77.83% であったのに対し全ての回帰アルゴリズムでの予測値はいずれも低い値になってしまった。我々の知見では、傾きが小さい差も小さいことに起因

表 4 XGBoost による予測値

No.	XGBoostによる予測値(%)	学習回数150回の分類精度(%)	誤差(%)
1	79.84	78.37	1.47
2	86.14	83.26	2.88
3	85.10	83.07	2.03
4	68.78	64.37	4.41
5	88.28	88.87	-0.59
6	79.46	81.65	-2.19
7	83.34	81.59	1.75
8	85.08	85.37	-0.29
9	83.37	82.76	0.61
10	82.27	78.96	3.31
11	79.44	82.33	-2.89
12	87.80	82.63	5.17
13	86.78	77.40	9.38
14	29.46	23.82	5.64
15	82.30	75.58	6.72

すると判断できるが、(a) と同じように差の項目を重要視できていないため精度の低いモデルと予測してしまったのではないかと考える。また、これらのモデルは学習回数 5 回の時点では判断できない可能性がある。このため、今後は今使用しているモデルデータセットに対し、額周布回数をどの程度に設定するかを検査が必要と思われる。




図 1 予測値との誤差が大きいモデルの学習曲線

6 まとめ

今回使用したモデルデータセットでは、3 種類の回帰アルゴリズムで求めた予測値と最終学習回数の分類精度の誤差が低く、十分な予測ができることを確認した。今後はうまく行かなかったデータや、予測に使用する学習回数の検討を行いたい。

謝辞

本研究の一部は JSPS 科研費 23K11266, 23H03387, 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] Chen, T. and Guestrin, C. "XGBoost: A scalable tree boosting system.", 2016.
- [2] Mizuki Dai, Kenya Jin'no, "Toward the realization of lightweight CNN", IEICE NOLTA2022
- [3] Alex Krizhevsky, "Learning Multiple Layers of Features from Tiny Images", 2009.
<http://www.cs.toronto.edu/~kriz/cifar.html>