

画像のエントロピーによる機械学習モデルの性能評価 Performance Evaluation of Machine Learning Models using Entropy of Images

阿部 莉子[†] 檀 裕也[†]

Riko ABE Yuya DAN

1. はじめに

AI 技術の発展により、画像認識の精度向上を図る研究が盛んに行われるとともに、様々なツールに応用され広まっている。なかでも一般物体認識において、CNN による機械学習が多く用いられている。ところが学習の際、無作為に学習画像を選定すると、低い精度の学習モデルが作成されたり、モデルの精度向上のためにより多くの学習画像が必要になるなど、学習効率が低下してしまう。

これまでに、統計物理学の概念であるエントロピーを情報分野に転用し、情報量を測った Shannon^[1]は、 $-p \log p$ の形で情報エントロピーを定義した。また Krizhevsky ら^[2]は一般物体認識において、初めて CNN が有効であると示した。

そして、エントロピーを使用した特徴抽出において、分類誤差に交差エントロピーを用いるケース^[3]や、データセット全体に対し特徴の粒度を捉える際に、ソフトマックスエントロピーを使って正則化する手法^[4]、少量のデータによる能動学習において、エントロピーを使い情報量が高いデータを選定する研究^[5]があるが、これらのエントロピーの計算方法では画像の形状や変化を見ることができず、微視的に特徴を捉えることができない。

そこで、CNN による機械学習において、精度の高いモデルと低いモデルそれぞれの学習画像およびテスト画像に対し差分フィルタを適用した微視的なエントロピーの計算手法により特徴を掴むことで、学習効率を向上させることができるのではないかと考えた。CIFAR-10^[6]の学習およびテスト画像に対し各種エントロピーを使って特徴を比較した実験の結果について述べる。

2. 実験

2.1 実行環境

Google Collaboratory の開発および実行環境で、機械学習およびエントロピー計算のプログラムを作成した。その際、用いたプログラミング言語は Python である。また、Python Image Library(PIL)のイメージモジュール、NumPy のモジュールおよび次元圧縮のライブラリである t-SNE モジュールを利用した。

2.2 エントロピーの計算手法

2 種類のエントロピーの計算手法を用いて特徴抽出を行う。

1 つ目のエントロピーは、RGB 3 チャンネルに分け、チャンネルごとに画素値 j の相対度数 p_j を求める。そして p_j を下の式に代入し、エントロピーを計算する。このエントロピ

ーを以下、「カラー画像エントロピー」と呼ぶ。

$$H_C = \frac{1}{3N} \sum_{j=0}^{255} \left(p_j^R \log \frac{1}{p_j^R} + p_j^G \log \frac{1}{p_j^G} + p_j^B \log \frac{1}{p_j^B} \right)$$

2 つ目は、RGB 3 チャンネルの各画素に対し、水平方向および垂直方向の微分フィルタを適用した画像の 256+256 階調の度数分布 (ヒストグラム) h_j から、各対応画素の比率 p_j を求めエントロピーを計算する。以下、「差分エントロピー」と呼ぶ。

$$H_D = \frac{1}{3N} \sum_{j=-255}^{255} \left(p_j^R \log \frac{1}{p_j^R} + p_j^G \log \frac{1}{p_j^G} + p_j^B \log \frac{1}{p_j^B} \right)$$

今回学習に用いたデータセット CIFAR-10 の訓練用画像 50,000 枚に対するカラー画像エントロピーと差分エントロピーの分布比較は図 1 のとおりである。




図 1 カラー画像エントロピー(青)と差分エントロピー(オレンジ)の分布比較

この時、カラー画像エントロピーの標準偏差が 0.000550 に対し、差分エントロピーの標準偏差は 0.000924 と、差分エントロピーの方が標準偏差が高い。

2.3 学習モデルの生成

CIFAR-10 の訓練用画像全 50,000 枚を、学習画像と検証画像に分け、学習画像をバッチサイズ 32 および学習率 0.01 に設定して学習モデル^[7]を 8 種生成する。そして生成した学習モデルに対し、検証画像 10,000 を用いて精度を計測した。この操作を 30 回繰り返す、それぞれ最も精度の良い学習モデルを採用する。下記に、生成した 8 種類のモデルについて詳細を記載する。

2.3.1 全画像学習モデル

訓練用画像を、ランダムに学習画像 40,000 枚と検証画像 10,000 枚に分け、学習モデルを生成する。

[†] 松山大学 経営学部 情報コース

Faculty of Business Administration, Matsuyama University

2.3.2 半数画像学習モデル

全画像学習モデルに使用した学習画像の半数である 20,000 枚を使用し、学習モデルを生成する。

2.3.3 高エントロピー画像学習モデル(2種類)

全画像学習モデルに使用した学習画像のうち、エントロピーの高い画像 20,000 枚を用い学習モデルを生成する。計算には先述した 2 種類のエントロピーを使用し、高カラー画像エントロピー学習モデルと高差分エントロピー学習モデルの 2 種類を生成した。

2.3.4 低エントロピー画像学習モデル(2種類)

高エントロピー画像学習モデル同様、全画像学習モデルに使用した学習画像のうち、エントロピーの低い画像 20,000 枚を用い学習モデルを 2 種類生成する。

2.3.5 トリム学習モデル(2種類)

全画像モデルに使用した学習画像のうち、極端にエントロピーの値が高いものを除き、学習モデルを生成する。各モデル学習画像の枚数はそれぞれ 39,876 枚である。

2.4 実験方法

1.3 で用意した 8 種の学習モデルそれぞれに対し、モデルごとの精度や特徴を比較する。精度比較では、テスト用画像 10,000 枚を用い、各モデルに対しテストを行う。

3. 結果

3.1 モデルの精度比較結果

各モデルの Loss(損失関数)と Accuracy(正確度)を表 1 に示す。

	Loss	Accuracy
全画像学習モデル	0.875	0.698
半数画像学習モデル	1.235	0.648
高カラー画像エントロピー画像学習モデル	8.011	0.158
高差分エントロピー画像学習モデル	1.737	0.475
低カラー画像エントロピー画像学習モデル	1.268	0.586
低差分エントロピー画像学習モデル	1.334	0.576
トリム学習モデル (カラー画像エントロピー)	0.860	0.712
トリム学習モデル (差分エントロピー)	0.880	0.721

表 1. Loss および Accuracy 比較図

表 1 より、トリム学習モデル(差分エントロピー)の精度が一番高く、高エントロピー画像を学習したモデル 2 つの精度が低いことが分かった。

次に、最も精度が高いトリム学習モデル(差分エントロピー)と、精度の低い高カラー画像エントロピー画像学習モデルの特徴量分布について図 2.3 に示す。



図 2. 特徴量分布
トリム学習モデル(差分エントロピー)




図 3. 特徴量分布
高カラー画像エントロピー画像学習モデル

2 つの図より、トリム学習モデル(差分エントロピー)ではクラスごとに特徴量がまとまっているのに対し、高カラー画像エントロピー画像学習モデルではクラスごとの特徴がとれておらず、クラス間の画像の判別がうまくできていないことが分かる。

また、学習および検証画像のクラス別のエントロピー分布を図 4.5 に示す。




図 4. カラー画像エントロピー




図 5.差分エントロピー

2つの図より、カラー画像エントロピーよりも差分エントロピーの方が画像ごとのエントロピーの分散が広いことが分かるが、高エントロピー画像学習モデルと低エントロピー画像学習モデルの精度比較の結果より、分散の広さに優位性はないことが分かった。またカラー画像エントロピーは色情報による特徴を捉えているのに対し、差分エントロピーは画像内の対象の形情報による特徴を捉えており、トリム学習モデル(差分エントロピー)が最も精度が高いことから、色情報よりも形情報が精度向上に対し有意であることが分かった。

3.2 クラスごとの正解率

次にトリム学習モデル(差分エントロピー)について、各クラスごとに行ったテストの正解率を図6に示す。グラフは青色の部分が正解画像、赤色の部分が不正解画像の割合を示し、横軸はクラス番号、縦軸は正解比である。またクラス番号と対応するクラスについては表2のとおりである。

0	airplane	5	dog
1	automobile	6	frog
2	bird	7	horse
3	cat	8	ship
4	deer	9	truck

表 2.クラス番号と対応クラス




図 6.正解率

トリム学習モデル(差分エントロピー)

図6より、テストの結果クラスごとの正解率には大ききばらつきがあることが分かった。特に、airplane, automobile, ship, といった乗り物の正解率が高いのに対し、bird, cat といった動物に関する画像の正解率が低いことが見て取れる。

4. おわりに

本研究では、データセット CIFAR-10 の画像を用い生成したモデルの精度比較を行ったが、結果より、エントロピーの極端に高い画像を除いた学習モデルは、他のモデルと比較し精度が高くなることが分かった。またエントロピーの高い画像には、クラスに該当する物体のほかに乱雑な背景情報が含まれていると推測される。よって高精度なモデル学習において、乱雑な背景情報はノイズとなることが考えられる。

そして今回の実験により、ノイズとなる乱雑な背景情報を含む画像を排除する効率的な手法として、エントロピーが有効であることが示された。特に、最も精度の高いモデルがトリム学習モデル(差分エントロピー)だったことから、画像のエントロピーの計算には、カラー画像エントロピーよりも差分エントロピーを用いることで、形情報を効果的に捉え、モデルの精度向上を図ることが可能である。

しかし、エントロピーと同等に学習画像の枚数が学習モデルの精度に影響していることや、乗り物と比べ動物に関する画像の正解率が伸び悩むといった課題が挙げられた。今後は、高エントロピー画像モデル等 20,000 枚で学習させたモデルの学習画像枚数を増やし、精度比較についての実験を行うと共に、エントロピーを用い、クラスに寄らず高い正解率を維持できるモデルの生成に努める。

参考文献

- [1] C. E. Shannon. "A mathematical theory of communication". SIGMOBILE Mob. Comput. Commun. Rev. Vol.5, no.1 (January 2001), pp.3-55. <https://doi.org/10.1145/584091.584093> (2001). Originally from The Bell System Technical Journal, Vol. 27, pp. 379-423, 623-656, July, October, 1948.
- [2] Krizhevsky, Alex, Ilya Sutskever and Geoffrey E. Hinton. "ImageNet classification with deep convolutional neural networks." Communications of the ACM 60 (2012): pp. 84 - 90. The Bell System Technical Journal, Vol. 27, pp. 379-423, 623-656. <https://dl.acm.org/doi/10.1145/3065386> (July, October, 1948)
- [3] 岡谷 貴之: "画像認識のための深層学習の研究動向: 畳み込みニューラルネットワークとその利用法の発展", 人工知能, 31 巻, 2 号, pp.169-179, (2016)
- [4] 齋藤 佑真, 萩原 将文: "複数のクラスタ性特徴を用いた多い粒度の表現学習", 日本知能情報ファジィ学会 ファジィシステムシンポジウム 講演論文集, 34 巻, 第 34 回ファジィシステムシンポジウム, セッション ID TC1-4, pp.382-387, (2018)
- [5] 赤穂 昭太郎: "少量のデータに対する機械学習", 電子情報通信学会 基礎・境界ソサイエティ Fundamentals Review, 16 巻, 4 号, pp.247-256, (2022)
- [6] Alex.Krizhevsky: "Learning multiple layers of features from tiny images," <https://www.cs.toronto.edu/~kriz/learning-features-2009-TR.pdf> (2009)
- [7] 田村雅人, 中村克行. Python で学ぶ画像認識, インプレス(2023)