

オンプレミス深層学習による頭部 CT 画像診断の試み

Diagnosis of head CT image by on-premise deep learning

白石 哲也*¹
Tetsuya Shiraishi

土方 友莉子*²
Yuriko Hijikata

*¹ 埼玉石心会病院リハビリテーション科
Rehabilitation Medicine, Saitama Sekishinkai Hospital

*² 同診療部
Clinical Department

We studied whether cerebral hemorrhage can be diagnosed correctly by deep learning with convolutional neural network using CT images taken at our hospital. Data processing techniques such as trimming-off and augmentation improved the precision rate of image classification. Generally, a large amount of image data is required for deep learning. However, it is often difficult to collect many cases in one hospital. Our results suggest the possibility of on-premise medical image recognition with deep learning in the future.

1. 概要

当院で撮影された頭部 CT 画像を用い、CNN(Convolutional Neural Network)を用いた教師あり学習により、脳出血を正しく画像診断できるかどうかを検討した。データを加工せずに解析を行った場合の認識率は低かったが、データのトリミング、データの水増しそして活性化関数や畳み込み層の最適化によって高い認識率が得られた。一般的に深層学習には大量の画像データが必要とされているが、少ない画像データでも高い認識率が得られた事は、今後オンプレミスでの人工知能開発の可能性を示唆するものである。

2. 目的

深層学習(Deep Learning:以下 DL と略す)を用いた人工知能(AI)アルゴリズムの中でも、CNN(Convolutional Neural Network)[Krizhevsky, 2012]は非常に高い画像解析能力を持っており、医療画像診断分野への応用が期待されている[Chartrand, 2017]。深層学習を画像認識分野に適応するにあたっては、大量の教師ありデータが必要とされている。そのため、保険医療分野 AI 開発加速コンソーシアムでは、高いセキュリティを持つ「厚労省認定メディカルクラウド」の設立を通して、全国の病院からの症例データ蓄積を目指している。どんなに高度なセキュリティであっても、破られる可能性が皆無ではないため、院内の個人データを院外に持ち出すことに躊躇する病院がたくさん出てくるのではないかと考えられる。個人情報及びメンテナンスの観点からは病院内で完結するオンプレミス型の開発が望ましいと考えられる。

オンプレミス型の開発には、少量のデータであっても高い画像認識率を得られる工夫が必要である。本研究では、当院で実施された頭部 CT 画像を用い、少量の画像データに対して、各種データ加工技術を加えることと、データ解析法を工夫することにより、画像診断に耐えられるだけの高認識率が得られるかどうかを検討した。

3. 方法

3.1 倫理面の配慮

当院の画像データを安全な個人情報管理のもとで使用するために、当院倫理委員会の承認(承認番号:30-37 号)を得た上で、個人を特定できる情報を除いたデータの選定と診療情報管理室におけるダブルチェックを行った。また解析に用いる個人用 PC は外部ネットワークと遮断した状態でコマンドを実行した。

3.2 対象症例

対象症例は 2017 年 11 月 1 日から 2018 年 10 月 31 日に当院で撮影した頭部 CT 画像の中で、脳出血あるいは脳出血疑いと診断された症例を用いた。頭部 CT のスキャンレベルは、脳出血の中でも頻度の高い視床出血及び被殻出血が描出されるモンロー孔レベルを選択した。頭部 CT で次の所見が認められる症例は除外した。すなわち陳旧性脳梗塞、複数病変、中等度以上の脳萎縮、著明なアーチファクトである。

今回の研究で用いた症例のカテゴリ識別番号と症例数を 2 クラス分類問題と 8 クラス分類問題に分けて表 1 に示した。

表 1 対象症例の識別番号、カテゴリ名および症例数

識別番号		カテゴリ名	症例数
2 分類	8 分類		
0(正常)	0	正常	145
1(異常)	1	被殻出血	33
	2	視床出血	26
	3	皮質下出血	13
	4	慢性硬膜下血腫	61
	5	くも膜下出血	9
	6	脳室内出血	8
	7	混合型基底核出血	8

3.3 画像データ加工と深層学習開発環境

頭部 CT 画像データの加工には Adobe Photoshop CC 2019 を使用した。図 1 のようにオリジナル画像(左)の頭蓋周辺の背景をトリミングし、解像度を 64x64 に変更した。

次に、データ水増し(Data Augmentation: 以下 DA) 処理を図 2 に示す。オリジナル画像(上段左)を時計方向(上段中)および反時計方向(上段右)に 2° 回転した。さらにオリジナル画像を左右反転した画像(下段左)に対して同様の画像回転処理を行った。




図 1 オリジナル画像とトリミング処理をした画像

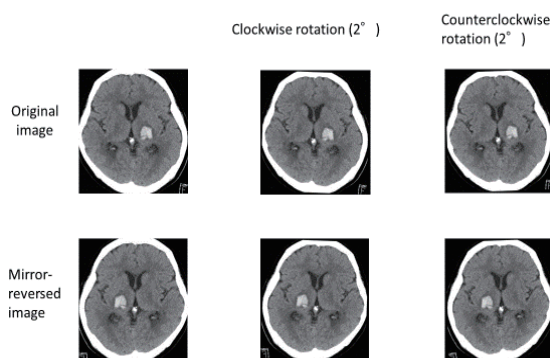


図 2 オリジナルおよび左右反転画像と回転画像

データセットの作成、ニューラルネットワークの構築そして学習・評価には、深層学習プログラム生成統合開発環境である SONY の Neural Network Console(windows 版)ver.1.20 を使用した。

4. 結果

4.1 2 クラス分類問題

解析には 3 層の畳み込み層/プーリング層を有する畳み込みニューラルネットワーク CNN を用いた。中間層の活性化関数は tanh 関数を、出力層にはシグモイド関数を用いて 2 値分類を行った。オプティマイザーは Adam を使い、パラメータは Learning Rate $\alpha=0.001$, $\beta 1=0.9$, $\beta 2=0.999$, $\epsilon=1e-08$ とした。オリジナル画像とトリム画像に対して DA の有無別に、合計 4 種類の画像入力データを用いて解析を行った。

y:label=0(正常)の認識率は 0.9825、y:label=1(異常)の認識率は 0.9787 であった。

データ加工と認識率の関連については、オリジナル画像のみの認識率が 0.6666 であったのに対し、DA を行ったデ

ータの認識率は 0.9472 と大幅に上昇した。またトリム画像のみの認識率は 0.8166 であったが、DA を追加した場合データの認識率は 0.9805 と認識率の改善を認めた。

4.2 8 クラス分類問題

解析には 3 層の畳み込み層/プーリング層を有する畳み込みニューラルネットワーク CNN を用いた。中間層の活性化関数は Swish 関数あるいは LeakyReLU を使い、2 層目の畳み込み層には Depthwise Convolution を用いた。出力層にはソフトマックス関数を用いて 8 値分類を行った。オプティマイザーは Adam を使い、パラメータは Learning Rate $\alpha=0.001$, $\beta 1=0.9$, $\beta 2=0.999$, $\epsilon=1e-08$ とした。

認識率は、0.983(ラベル 0: 正常)、0.977(1: 被殻出血)、1.000(2: 視床出血)、1.000(3: 皮質下出血)、0.973(4: 慢性硬膜下血腫)、1.000(5: くも膜下出血)、1.000(6: 脳室内出血)、0.889(7: 混合型基底核出血)であった。

データ加工と認識率の関連については、オリジナル画像データに DA を追加したデータの認識率が 0.9065 であったのに対し、トリム画像に DA を追加したデータの認識率は 0.9807 であり、トリム画像を使用の方が、認識率の改善が得られることが示された。

5. 考察

8 分類課題では、10 例前後と非常に少ない症例数でも、トリミングやデータ水増しの前処理を行い、さらにネットワーク構造をチューニングする事で、高い認識率を達成することが出来た。このことは、一つの病院で経験されるデータのみを用いても、精度の高い画像診断 AI を構築することが出来る可能性があることを示唆している。

このように少数のデータで高い認識率を達成出来たのは、頭部 CT 画像がもつ特徴が関係していると思われる。すなわち、画像ノイズが少ないこと、左右反転した画像も同じ価値を持つこと、頭部の位置の微妙なズレによりもともとある程度の回転画像になっていることなどである。

医用画像には撮像部位の違いや用いる物理パラメータの違いにより様々なものが存在する。しかし、それぞれの画像の特徴に応じた、データ加工技術を用いることで、画像認識の適応範囲を広げることが出来ると思われる。

参考文献

- [Krizhevsky 2012] Krizhevsky A, Sutskever I, Hinton GE: ImageNet classification with deep convolutional neural networks. Advances in Neural Information Processing System 25 (NIPS 2012), 2012.
- [Chartrand 2017] Chartrand G, Cheng PM, Vorontsov E, et al.: Deep learning: a primer for radiologists. RadioGraphics 37:2113-2131, 2017