

3次元脳MRI画像解析における3D-CNNと2D-CNNの識別性能比較

1265092 岡本 幸輝 【 知能情報研究室 】

Comparison of 3D-CNN and 2D-CNN in Analysis of 3-Dimensional Brain MRI Images

1265092 OKAMOTO, Koki 【 Intelligent Infomatics Lab. 】

1 はじめに

医療分野へのAIの活用として3D脳MRI画像を対象とした3D畳み込みニューラルネットワーク(3D-Convolutional Neural Network:3D-CNN)による画像認識が研究されている。3D-CNNは画像サイズが大きいため、大容量のGPUメモリ等の高性能な計算機が求められる。本研究では、主流である3D-CNNではなく3次元画像を2次元画像へ変換しリソースを削減しつつ高精度で男女の識別を行うことを目的として次元削減を行い2D-CNNを用いて学習を行う。これによって計算コストの削減をはかる。また、2次元画像を対象とすることで、2次元の一般画像で学習済みのモデルを用いた転移学習が可能となり、精度の向上も期待できる。そこで、MRI脳画像の男女識別を対象として、3D-CNN, 2D-CNN, およびVGG16, VGG19, ResNet50の事前学習済みモデルで、分類精度, 学習速度の比較を行う(図1)。

2 提案手法

3次元を直接畳み込むモデルではGPUメモリと計算時間を消費する問題がある一方で、3次元画像には冗長性が多く、分類・判別そのものはもっと少ない情報でもできるのではないかと考える。そこで、3次元画像から2次元スライスをとることで、2D-CNNを用いての分類モデルを提案する。笹谷[2]らが用いた3D-CNNを2次元化した2D-CNNを構築し、3D-CNNを用いて高精度だった[1]頭蓋あり画像と頭蓋なし画像の線形・非線形レジストレーション画像に対して男女識別を行う。また、2次元データを扱うことで2次元一般画像で学習済みのモデルを用いた転移学習が可能となるので事前学習済みモデルを用いての男女識別も行う。

3 実験内容

データセットはロンドンの異なる3箇所の病院で収集された581人のT1強調画像が含まれるIXI-Datasetを使用する。画像への前処理としてA.頭蓋あり線形レジストレーション, B.頭蓋なし線形レジストレーション, C.頭蓋あり非線形レジストレーション, D.頭蓋なし非線形レジストレーションのサイズが(91, 109, 91)である4

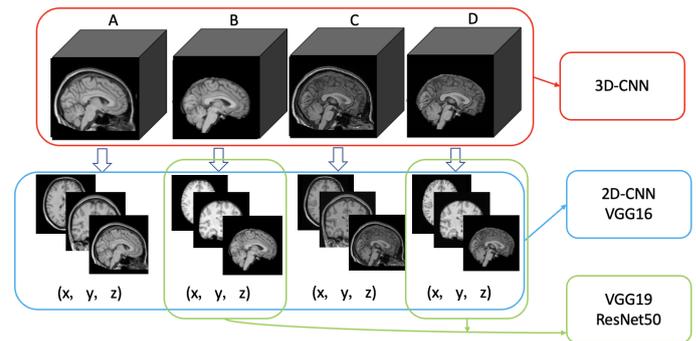
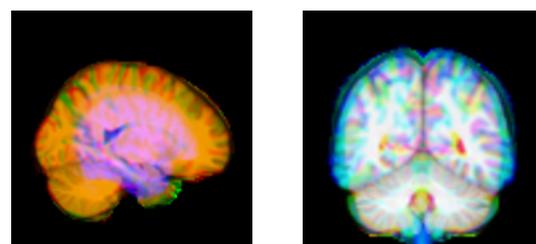


図1: 3D-CNNと2D-CNN比較

画像を作成し(x, y, z)軸の3軸のスライスをそれぞれ全スライスを抽出する。その後(224, 224, 3)のサイズになるようにリサイズしアスペクト比を調整する(図1)。画像A, Cに対しては作成した2D-CNNモデル, 事前学習済みのVGG16, 事前学習済みのVGG19, ResNet50, 幾つかのスライスに対し事前学習無しのVGG16を用いて男女識別タスクを行う。学習におけるepoch(以下ep)数は3D-CNN, 2D-CNNで150ep, VGG16で50ep, VGG19, ResNet50で100epである。2性能評価はAccuracyを用い, チャンスレベルは女性66人男性53人の55%である。加えて, 事前学習済みモデルでは3チャンネル画像(カラー画像)用のモデルのため, スライス情報を3つまで入力することができるため, 図2のような単一のスライスで高精度な分類ができた上位3つ



(a) 画像 B.x

(b) 画像 B.y

図2: 上位3スライス合成画像

表 1: 平均実行時間 (エポックごと) とパラメータ数

| model | 3DCNN | 2DCNN | VGG16 | VGG19 | ResNet50 | VGG16 untrained |
|---------------------------|-------|-------|-------|-------|----------|-----------------|
| Avg. trainingtime[sec/ep] | 30.3 | 6.2 | 6.4 | 6.8 | 7.7 | 90 |
| param | 41K | 10K | 14M | 20M | 23M | 14M |

表 2: モデルごとの Accuracy

| Image&Axis | A.x | A.y | A.z | B.x | B.y | B.z | C.x | C.y | C.z | D.x | D.y | D.z |
|---------------|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|
| 2DCNN | 89 | 88 | 89 | 71 | 71 | 74 | 91 | 90 | 90 | 75 | 73 | 74 |
| VGG16 | 98 | 97 | 98 | 85 | 84 | 85 | 97 | 97 | 97 | 82 | 82 | 81 |
| VGG16(3ch) | | | | 78 | 74 | 73 | | | | 70 | 74 | 67 |
| VGG19 | 95 | 96 | 96 | 85 | 84 | 80 | 97 | 96 | 97 | 85 | 80 | 80 |
| ResNet50 | 100 | 98 | 98 | 89 | 87 | 91 | 100 | 97 | 99 | 87 | 87 | 82 |
| ResNet50(3ch) | | | | 87 | 86 | 80 | | | | 81 | 82 | 79 |
| 3DCNN | | 82 | | | 71 | | | 83 | | | 55 | |

のスライスからなる3チャンネル画像を使って事前学習済みのVGG16, ResNet50で学習させた。

4 実験結果・考察

4.1 3D-CNNモデルと2D-CNNモデルの比較

表1, 表2では各モデルのエポックごとの時間, パラメータ数, 精度をまとめている。3D-CNNと2D-CNNでは, パラメータ数が約1/4ほどになりエポックごとの学習時間も約4.9倍ほど速度の向上が見られた。また, 精度においても3D-CNNよりも2D-CNNの方が高精度での識別を可能としたスライスがあり, 画像Dにおいて, 3D-CNNでは55%とチャンスレベルと同等であり識別不能であったが約20%ほど向上した。

4.2 事前学習済みモデルとの比較

事前学習済みモデルのVGG16, VGG19, ResNet50ではパラメータ数が最大で約560倍にまでなっており, パラメータ数に応じて学習時間は伸びるものの学習速度は向上する結果となった。精度においても, 畳み込み層の数に応じて精度が向上するような傾向があり, 頭蓋なしの画像B, DでもResNet50で最大91%と高精度での識別を可能とし, 幾つかのスライスで試験的に事前学習無しのVGG16を用いてのタスクを実行したところVGG16とパラメータ数は変わらなかったものの学習時間が約14倍と速度の低下が著しかった。精度に関しては表には記述していないものの事前学習済みよりも5~10%ほど低下していた。これらのことから, パラメータ数の大きなVGG16などのモデルも事前学習済みであれば精度, 学習速度の向上が見られたことから事前学習済みモデルの有用性が示され, 3次元MRI画像を2次元

に落とし込むことでこれらのモデルで転移学習を行えることも強みであると考えられる。最後に高精度だった上位3スライスを合成したB, D画像に対してVGG16とResNet50を用いてタスクを行ったものの, どれも精度の向上は見られなかった。

5 おわりに

本研究では, 前処理した3次元脳MRI画像を1スライスごとに全抽出することで2次元へ落とし込み, 3D-CNNモデルと2D-CNN, および事前学習済みモデル, 事前学習無しモデルを用いて男女識別を行なった上で性能の比較を行った。その結果, スライスによっては3D-CNNの結果を大きく上回る精度を記録し画像Dにおいては識別不能だったレベルから最大で87%という精度を, 画像B, DではResNet50で最大91%の精度を得た。また, 計算時間においても3D-CNNと比較すると約3.9倍ほど短縮することができた。加えて, 事前学習済みモデルの有用性が示されたことで2次元に落とし込んだ時に転移学習が行えることが有利に働くといえる。しかしながら, 高精度を得たスライスが同軸で完全に一致しているわけではないことからスライスと脳部位を照らし合わせて考察する必要がある。

参考文献

- [1] 藤沢, “深層学習による3次元MRI脳画像分類モデルの説明可能性に関する研究,” 高知工科大学大学院修士論文, 2021.
- [2] Takenobu Sasatani, “Prediction of human characteristics from brain structural mri using cnn”, International Symposium on Frontier Technology (ISFT-2019), 529/533 (2019)