

## 深層学習の放射線治療への応用



脇田 明尚\*<sup>1</sup>  
Wakita Akihisa



小林 和馬\*<sup>1,2</sup>  
Kobayashi Kazuma



浜本 隆二\*<sup>2</sup>  
Hamamoto Ryuji



伊丹 純\*<sup>1</sup>  
Itami Jun

### 1 はじめに

近年、人工知能（AI; Artificial Intelligence）の進化はすさまじく、新聞・テレビ・インターネット等の各種メディアで目にしない日は無いと言っても過言ではないであろう。2012年のGoogle社による猫画像認識、2016年のDeepMind社によるAlphaGoが人間の囲碁王者に勝利する等、AIは人間特有と思われていた能力を獲得し、特定のタスクにおいては人間を超える能力を獲得しつつある。身近な例で言えば、近年盛んに開発が進められている自動車の自動運転技術にもAI技術が使用されている。

このようにAI技術はその進歩と共に産業へも応用され始めているが、一口にAIと言っても実は多様な技術が存在している。中でも、近年のAIの目覚ましい進化を支える技術の筆頭として深層学習が挙げられる。本稿では、深層学習についての基礎的な内容から、実際の放射線治療への応用について解説する。

### 2 深層学習について

深層学習とは、多層のニューラルネットワークによる機械学習手法である。多くのAI技術がこの「機械学習」をベースとして成り立っているが、深層学習がその他の機械学習技術と異なる点として、それ自体が特徴量を抽出しながら学習を行う、という点

が挙げられる。例えば、いくつかの画像の中から「猫の画像」のみを機械により抽出したいとする。このとき、ルールベース・プログラムを用いた手法、従来の機械学習を用いた手法、深層学習を用いた手法の3つを考える（図1）。ルールベースの場合、目が2つあって、ひげがあって等、何らかの方法で人間が「猫」を定義しなければならない。そして、それらの定義すべてに合致する場合に「これは猫である」と判断するということになる。従来の機械学習手法を用いた場合、「猫らしさ」を表す指標を人間が定義し、猫と猫以外の画像群から「猫らしさ」指標がいくつ以上であれば猫なのか、を学習する。そして新しい画像に対しても「猫らしさ」指標を計算し、事前に学習して得られた数値を上回れば「これは猫である」と判断する。一方で深層学習を用いた場合、猫と猫以外の画像群をニューラルネットワークに入力し、正解か不正解かを教えてあげるのみで学習が完了する。そして新しい画像を訓練されたニューラルネットワークに入力すれば、正解・不正解を出力し、正解であれば「これは猫である」と判断する。図1に示すとおり、深層学習を用いた場合、



図1 3つの手法とそれぞれの人間の作業と機械の作業の内訳

信号：  $x_1, x_2$   
 重み：  $w_1, w_2$   
 入力：  $y = w_1x_1 + w_2x_2$   
 活性化関数：  $f$   
 出力：  $f(y)$

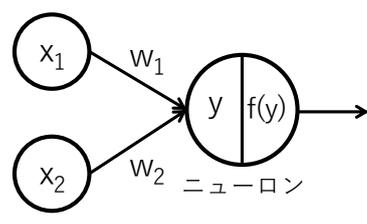


図2 ニューラルネットワークの基本構造

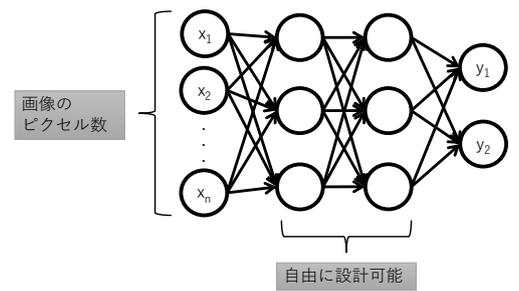


図3 猫画像判別用ニューラルネットワークの例

ニューラルネットワークの定義を除くと、ほぼ人間の作業が必要無くなるということが非常に大きなポイントとなる。

### 2.1. ニューラルネットワーク

深層学習では多層のニューラルネットワークを使用する。一般には、ニューラルネットワークは脳の神経伝達を模擬したものとして紹介される。いくつかの信号がニューロン（神経細胞）へ入力されると、内部で演算された結果が出力され、その出力信号が更に入力信号となり次の層のニューロンへ伝達される、というのが基本的な仕組みである。実際には図2のように、それぞれの信号は重み  $w$  を乗算してからニューロンへ入力され、それらを線形に足し合わせたものに対して活性化関数と呼ばれる演算が行われた結果が出力となる。これが基本構造となり、この構造を用途に応じて組み合わせ、層を重ねることで深層学習に用いられるニューラルネットワークが完成する。層の数や1つの層の中に含まれるニューロンの数、活性化関数の種類等のネットワークの構造は任意に決定することが可能で、学習の結果にも影響を与える。前述の猫画像の例で言えば、最初の入力には画像のピクセル値  $(x_1, x_2, \dots, x_n)$  を与えることが一般的であるため、入力層の数は画像のピクセル数となり、出力層の数は正解／不正解の2個  $(y_1, y_2)$  となる。その間の層は自由に設定可能であるが、通常はデータの種類やタスクの種類に応じて、経験的に最適だとされている層間の接続法が選択される（図3）。

### 2.2. ニューラルネットワークの訓練

ニューラルネットワークの設計を行った後はどのようにして学習を進めていくのであろうか。そこで

必要になるのが、ニューラルネットワークの訓練と呼ばれる工程である。猫画像判別用のニューラルネットワークに初期値として重み  $w^{(0)}$  を与えた場合を考えてみよう。入力値は画像のピクセル値  $x_1, x_2, \dots, x_n$  であり、設計したニューラルネットワークに従って順番に計算を行えば出力として2個の値  $y_1, y_2$  が得られる。最終的には入力された画像が猫の場合には  $(y_1=1, y_2=0)$ 、そうでない場合には  $(y_1=0, y_2=1)$  となることが望ましい。そのような出力を得るために重み  $w^{(0)}$  を最適な値に更新していくことがニューラルネットワークの訓練となる。重みを最適にしておくためには何らかの指標が必要となり、深層学習においてはその指標は損失関数と呼ばれている。損失関数は様々なものが使用されるが、一般的には現在の重みで求めた  $y_1, y_2$  の値が、求めたい結果（入力された画像が猫の場合には  $(y_1=1, y_2=0)$ 、そうでない場合には  $(y_1=0, y_2=1)$ ）に近くなるほど小さくなるような関数を設計し、損失関数が最小となるように重みを最適化していく流れとなる。対象となる画像群をニューラルネットワークに入力→出力を計算→損失関数を計算→損失関数が小さくなるように重みを更新、という1サイクルの作業はエポックと呼ばれ、通常は数十～数百エポックの繰り返しを経て最適な重み  $w$  を計算し、ニューラルネットワークの訓練が完了する。

### 2.3. 新規画像でのテスト

ニューラルネットワークの訓練が完了した後は、「訓練に使用しなかった画像」を用いたテストを行う必要がある。これは、ネットワークが訓練に使用した画像以外に対しても高い判別能力を持っているかどうかを確認するための工程である。こういった性能は「汎化性能」と呼ばれる。反対に、訓練に使

用した画像にのみ正解を出すような最適化がなされている状況を「過学習」と呼び、できるだけ過学習がなく汎化性能の高い学習を行うことが重要となる。この工程でも正しく猫画像が認識されて初めて訓練が成功していたかどうか判断可能となる。

### 3 放射線治療への応用

深層学習の流れについて概説を行ったが、応用を考える上で重要な点として、ニューラルネットワークの設計が自由であることから、入力値として非常に幅広いデータを受け取ることが可能であること、入力に対する正解データさえあれば学習が可能であること、が挙げられる。つまり、手元にデータ（入力／正解）があり、ニューラルネットワークの設計さえ可能であればそれだけで自らの興味ある分野へ応用可能なのである。実際に放射線治療への応用として国立がん研究センター中央病院では、現在のところ全脳照射に対する自動治療計画の作成及び脳MRI画像に対する自動セグメンテーションについて一定の成果を得ているので、これを紹介する。

#### 3.1. 全脳照射に対する自動治療計画

放射線治療において、多発脳転移を有する患者への全脳照射（脳全体へ放射線を照射すること）は緩和治療として重要な意義を持っている。脳全体をターゲットとする全脳照射の照射野の設計においては、照射野に含めるべき対象臓器と避けるべき正常臓器の患者ごとの違いが小さく、その設計法は比較的テンプレート化しやすい。一方で、対象患者数が多い照射法であるために、照射野設計に対する自動アシスタントが深層学習により可能となるかどうかの検討を行った。

通常X線治療においては、マルチリーフコリメータと呼ばれる装置を用いて患者の腫瘍の形状に合わせて放射線の照射を行う。全脳照射では脳全体がターゲットとなっており、実際の治療計画ではCT画像から脳全体を描出し、これを十分にカバーするような照射範囲（図4）をマルチリーフコリメータにて設定している。つまり、深層学習ではCT画像を入力とし、マルチリーフコリメータで設定される照射野を正解として学習を行えば目的が達成されるということになる。ニューラルネットワークについて

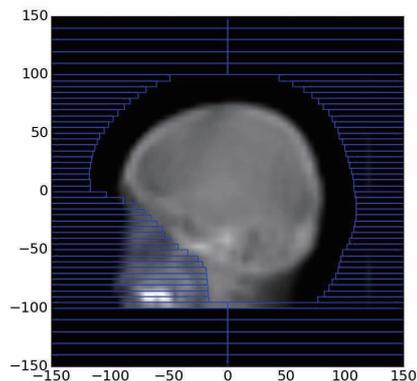


図4 全脳照射の照射野の一例

青線で示される多数の棒状の装置がマルチリーフコリメータである

ては、Oxford大学のVisual Geometry Groupが設計したVGG-16というネットワークを参考に構築し、当院で実際に全脳照射の治療を行った約300例のCT画像と照射野データを用いて学習を行った。得られた結果の一例を学習の様子を含めて図5に示す。定性的な評価となるが、おおむね良好な結果が得られており、30エポックほどの学習で現実的なレベルまで学習が進むことが示唆されている。

#### 3.2. 脳MRI画像に対する自動セグメンテーション

放射線治療において、腫瘍及び正常臓器をCTやMRI画像から描出する作業は非常に重要な工程である。描出された腫瘍や正常臓器に基づいて治療計画が作成されるため、描出精度が臨床結果に直結し得る。つまり、この作業は医師にとって最も重要な診断行為の1つであると言える。このような重要な工程に対して、深層学習による自動化はどこまで実現可能であろうか。今回、1個～数個の転移性脳腫瘍を有する患者のMRI画像を使用し、深層学習により腫瘍/正常臓器のセグメンテーションが可能かについて検討を行った。

学習には93例の入力として脳MRI画像と正解としてセグメンテーション済みの画像を用い、ニューラルネットワークは3D U-netと呼ばれる構造を利用した。70エポックの学習後、学習に使用していない画像に対して93.4%の精度で正解データを再現することが可能であった。図6にいくつかの断面でのセグメンテーション結果を示す。視覚的にも高い精度で輪郭描出されており、深層学習の非常に高い汎化性能が窺えると言えるであろう。

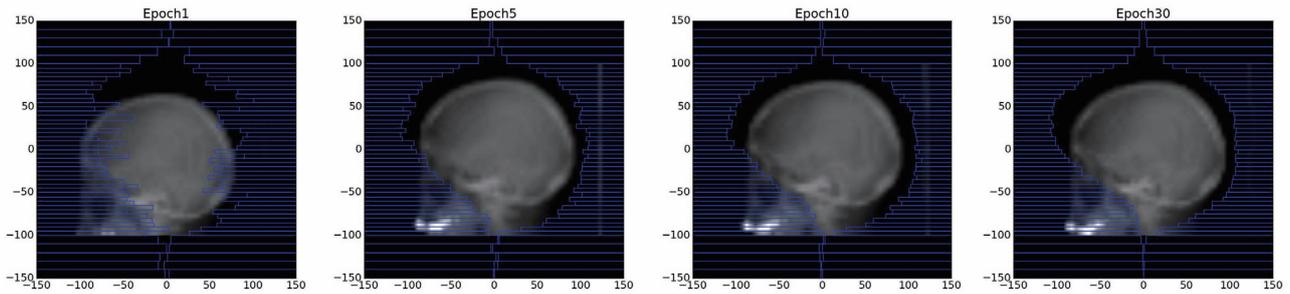


図5 得られた学習結果の一例

図左より 1/5/10/30 エポック後の学習結果

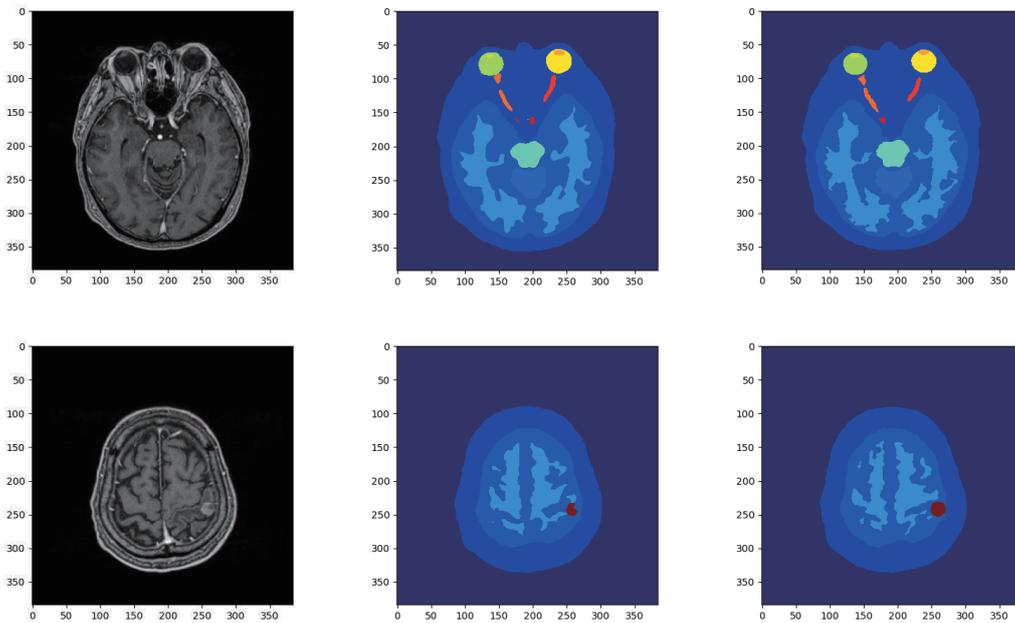


図6 入力MRI画像(左)と深層学習による予測画像(中央), 人の手による正解画像(右)の組

上の組は眼球や視神経を含むレベル, 下の組は腫瘍の存在するレベルの画像である。頭蓋内の構造のみならず脳内の構造や腫瘍まで高い精度で予測可能であった ((株)Preferred Networks との共同研究)

## 4 おわりに

本稿では近年のAIブームを支える技術である深層学習について簡単な解説を行い、放射線治療での応用例について示した。全脳照射の応用例等の比較的単純な例から、脳画像のセグメンテーションのような複雑な例まで、深層学習という同一の手法を用いて異なるタスクが実行可能であることが示せたかと思う。これらの結果は必ずしも深層学習でなければ得られないわけではなく、他の機械学習手法を用いても(あるいは全脳照射の例はルールベースでも十分)実現可能であろう。ただし、特筆すべきは、筆者らは「データを準備してニューラルネットワー

クへ入力しただけ」であるということである。もちろん細かなノウハウ等が多く存在することは事実であるが、他の手法で必ず必要となる「アルゴリズムを考える工程」が今回示した深層学習の例には存在しない。これは驚くべきことではないだろうか。データさえあればお示ししたとおり応用可能性は無限とも言えるであろう。今後も様々な応用例が示され、実臨床へも導入されていくことが予想されるが、本稿がその際の理解の一助となることを期待するものである。

(\*1 国立がん研究センター中央病院 放射線治療科,  
\*2 国立がん研究センター研究所 がん分子修飾制御学分野)