

人工知能と深層学習 AI and deep learning

相島 健助*¹
AISHIMA Kensuke

1 はじめに

近年、人工知能 (AI) や深層学習 (ディープラーニング) という言葉が社会的にも非常に注目されている。囲碁や将棋のソフトが人間のトップに勝ったというニュースが流れたり、自動運転技術の開発と結びつくことで、人工知能や深層学習は日常生活に馴染みのあるレベルで人々に影響を与えることを実感できるようになってきている。将来的に、人工知能により多くの仕事が無くなるなどといった議論もある。

本講演では、[1] を参考に、人工知能を学習の機構と解釈し、つまり大量のデータからの特徴検出およびパターン認識により、あたかも人が自律的に考えているかのように見せる技術と解釈しそのメカニズムについて議論する。農業農村工学分野においても、画像処理や水管理の技術は重要視されており、上記の意味でのパターン認識・汎化のための学習理論は重要と言える。

2 歴史・変遷

人工知能は人類の歴史の中で、実は三回に渡り注目を集めてきた。前述の通り、本講演では人工知能を機械 (計算機、コンピュータ) によりまるで人間の思考のように見せる技術と解釈して、コンピュータによる学習のメカニズムを説明する。歴史を振り返ると、人工知能はその黎明期において、歴史的にも最高レベルの頭脳を持ち主と考えられている数学者 (計算機科学者) の手で押し進められてきた。1950 年頃の第一次人工知能ブームでは、論理 (ルール) をベースにコンピュータの膨大なデータに対する高速演算により人工知能の実現が期待された。この頃の研究がその後の発展に大きく寄与するのだが、同時に限界も明らかになり人間のような知能は実現しなかった。これにはいくつか理由があるが、それほど難しく考えずとも、自分自身で物事を考える際に、論理 (ルール) のみで答えを導くのは難しく、過去の自分の経験や周囲の人の助言や実例に基づき判断する方がやり易い場合が多いことは実感できるのではないだろうか。

上記の考察から、人工知能は学習のメカニズムと結びつくことが分かる。つまり、何かしら人間の脳に入力されるデータに相当するものに対して、それがどのような特徴・パターンをもつかを学習 (認知) する、そのやり方を人間がプログラムすることが興味の対象となる。1980 年頃の第二次人工知能ブームでは、ニューラルネット (多層のパーセプトロン) をベースに様々な研究・開発が行われ、画像や音声の認識・処理や文字認識・言語処理などにおいて実用化された。そして現在、多層のニューラルネットワークの研究が計算機の能力の目覚ましい発展と相まって、あたかも人間の思考に相当する部分がコンピュータで実現できる (ように見える) ようになり、第三次の人工知能ブームを巻き起こしている。

以下では、基本となる線形変換による主成分分析や分類の仕組みを説明し、特に、単純パーセプトロンとサポートベクターマシンによる分類の議論から、多層のニューラルネットワークについて説明する。

3 線形変換と非線形活性化関数

回帰分析や主成分分析のようなデータ分析に代表されるように、空間上に散布するデータ点に対して、傾向を見るために適切に直線を引き、これに基づき新たな入力に対して何らかの予測 (汎化) を行うことができる。こ

*1 法政大学情報科学部 Faculty of Computer and Information Sciences, Hosei University

キーワード：人工知能, 深層学習, ニューラルネット, ニューロン発火, 最適化, クラスタリング

れと同じように、直線によりデータを二分し、適切なクラスタリングを行う技術は重要であり、ここで基盤になるのが適切な線形変換である。

データに対するクラスタリングと線形変換の重要な関係性を見るために、脳の数理モデルについて考える。これはニューロン発火の数理モデルであり、ニューロンのシナプス結合によるネットワークのことである。今仮に、ニューロンへの入力を三変数 x_1, x_2, x_3 とし、これらを w_1, w_2, w_3 の重み付きで足し合わせ、ある閾値 c を超えた時に発火する、という数理モデルを考えると以下のように記述できる。

$$y = \begin{cases} 0 & (w_1x_1 + w_2x_2 + w_3x_3 < c) \\ 1 & (\text{otherwise}) \end{cases}$$

今、入力に相当する与えられた三次元空間上のデータ点 x_1, x_2, x_3 が大量に分布しており、この大量のデータ点がある平面で2つに二分できるような偏りがある状況を考える。このとき、上式において $w_1x_1 + w_2x_2 + w_3x_3 = c$ は重み w_1, w_2, w_3 と c を適切に調整することで求めたい平面が得られる。サポートベクターマシン等はこの数理最適化問題を解く技術である。

データ点を平面で分割したい場合は上のやり方でよいが、現実のデータは必ずしも平面が適切とは限らず曲面であることが多い。この状況は合成関数の導入により数学的に表現でき、さらに確率勾配法により最適化問題が拘束に好ましく近似的に解ける。これが深層学習の数理的基盤である。

4 深層学習

深層学習と呼ばれるもので用いられるのは上記の単純パーセプトロンのような単純な入力と出力だけの二部グラフに相当するようなネットワークでは無く、多層のニューラルネットワークである。

先の説明で入力を x_1, x_2, x_3 出力を y としたが、 y が最終的な値では無く、中間層（隠れ層）に相当すると考え、ここでは h_1, h_2 の二変数であることを考えると以下のように記述できる。

$$h_1 = \begin{cases} 0 & (w_{11}x_1 + w_{21}x_2 + w_{31}x_3 < c_1) \\ 1 & (\text{otherwise}) \end{cases}$$
$$h_2 = \begin{cases} 0 & (w_{12}x_1 + w_{22}x_2 + w_{32}x_3 < c_2) \\ 1 & (\text{otherwise}) \end{cases}$$

今、(最終的な) 出力 y は、この h_1, h_2 の重み付き和が閾値を超えた時に発火する変数と見なすと、以下のよう記述できる。

$$y = \begin{cases} 0 & (w_1^{(1)}h_1 + w_2^{(1)}h_2 < c_3) \\ 1 & (\text{otherwise}) \end{cases}$$

最初の直線によるデータの分類の式と見比べると、上の三つの h_1, h_2, y の式はすべて単体として見ると同様である。つまり合成関数による表現になっており、最適化を施す際の勾配の計算はここでの(単純な)合成関数の構造に着目すると効率的な計算が可能である。深層学習の背後にある数学理論は、簡単にまとめれば以上のように線形変換と非線形活性化関数の合成を階層的に行った上で、適切に定式化された数理最適化問題を確率勾配法で効率的に(近似的に)解く技術である。必ずしも万能では無く、回帰分析や主成分分析の方が適切なデータも存在し、適切な分析手法を選択するべきである。

参考文献

- [1] 鈴木大慈：「機械学習技術の進展と その数理基盤」, 数理システムユーザーコンファレンス 2017.
<http://www.msi.co.jp/userconf/2017/pdf/muc17.pdf>