

ディープラーニング と 船舶性能

一色 浩

(有)数理解析研究所

2018.10.19

第11回推進運動性能研究会(長崎)

30年近く前にニューロを勉強しました。日立造船の技研にいたのですが、立体駐車場が必要となる車番認識の開発をしていました。

当時のニューロは、教えたことは正確に答えるけれど、教えてないものにはとんでもない答えを出すというお粗末なものでした。

いわば、受験秀才のようなものです。こういうのを汎化能力がないと言います。

ニューロは役に立たないということになって、一辺に下火になりました。ニューロ冬の時代の到来です。

最近になって連日ニューロが話題になっています。画像認識、音声認識、機械翻訳などの世界で大きなブレイクスルーが生まれました。

自動運転の技術が夢から現実になりました。

たまたま断れない講演依頼の話がありましたので、3ヶ月ほど掛けて9回ニューロの講義をしました。

そのために、色々調べましたが、信じ難い程の大きなブレイクスルーがありました。

今日はそのことを取り上げます。

本日の話の概要

NNは**人間の脳**の働きを模したもの。

階層NNは**入力と出力の非線形な関数関係**を求める。

多層NNは**どんな問題**(関数関係)も解ける。

入出力変数が**画像でも音声でも言語でも良い**。

多層NNを最小値問題で解くと**局所解**に捕まる。

ヒントンが解決し**人間よりも優れた画像認識**を示した。

その際、**人の視覚**を模した**畳み込みNN**を導入した。

ヒントンによる**ディープラーニング** → 大爆発

自己符号化器は**ノイズ削減**に有効。

天気予測等の**時系列**には**過去記憶するRNN**がある。

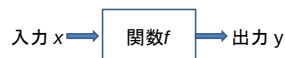
数学が嫌いでもいい。パソコンの能力が低くてもいい。

目 次

1. 知識を獲得する2つの方法
2. ニューロの歴史
3. 学習とは
4. 深層学習とは何か?
5. 深層学習ニューロの応用
6. 学習の手引き
7. 終わりに...AIで人類は進歩する?

1. 知識を獲得する2つの方法

知識...事物の関係を把握...事物間の関数関係



関数

数学的論理的に捉える...数学関数

(RBA: Rule Based Approach)

ニュートン力学の大成功:現代科学の原動力

経験的直感的に捉える...ニューロ

(DBA: Data Based Approach)

現代科学の行き詰まりに対するブレイクスルー

音声認識, 翻訳
最近著しく性能が向上

(Google翻訳, スマホ, AIスピーカ)

統計学的方法→深層学習ニューラル・ネットワーク

できれば更新する

2018.07.23 NHK-World-Japan

The commander of US Forces Korea has stressed the need to carefully study whether North Korea is sincere about abandoning its nuclear capabilities.
米軍司令官は、北朝鮮が核能力を放棄することについて誠実であるかどうかを慎重に検討する必要性を強調した。

General Vincent Brooks **addressed** a gathering on national security in the **western** US state of Colorado on Saturday.

Vincent Brooks将軍は、土曜日にコロラド州**西部の州西部**で国家安全保障に関する集会に**取り掛かった**。

画像認識能力

RBA...バーコード, 郵便番号, 活字, 指紋

・ケースが限られているものはすべてのケースを覚えればよい。

・手書き数字の標準データ: 28×28 ピクセル

...白黒の場合でも場合の数は 2 の 28×28 乗で全数学習は不可能。

DBA...2015年にNNが人間を越える。

2. ニューロンの歴史


2.1 大脳の構造 ... ゴルジとカハーンの研究

ニューロンの形状を明らかにしたのはイタリア人のカミッロ・**ゴルジ**で, 1873年に銀とクロムを用いた細胞の**染色法**を編み出して**神経細胞の観察**に成功する。

スペインのサンティアゴ・ラモン・イ・**カハール**は, **シナプス**では**軸索終末と樹状突起は直接つながっていない**で狭い隙間があることを主張した。ゴルジは継っていると考えた。光学顕微鏡では直接確認できないため見解が別れたが, 結果的にはカハールが正しかった。

ニューロン同士が直接継っていない事には, 信号処理上, 深い意味がある。

人間の脳には, 1000億個以上の下図のような神経細胞(ニューロン)がネットワークを形成している。



瀬雅人「これなら分かる深層学習入門」図3.1

神経細胞の数は大脳で数百億個、小脳で1000億個、脳全体では千数百億個にもなる。


一つの神経細胞からは, 信号を出力する長い「**軸索**」と, 信号を入力する木の枝のように複雑に分岐した短い「**樹状突起**」が伸びている。

軸索終末と樹状突起との間には**シナプス**があり, 信号が伝達される。

シナプスでは軸索を伝わってきた電気信号を受けると, **シナプス小胞**というカプセルに詰め込まれた**神経伝達物質**と呼ばれる化学物質を放出する。

樹状突起の**レセプタ**が受けると**電気信号**が細胞体(中央の膨らみ)に向けて出される。

細胞体では樹状突起から上がった全信号を合算し, それがしきい値を超えると軸索に向けて電気信号を発する。



活動電位と電気パルスの伝播

電気信号は連続パルスからなる。パルスの振幅は決まっており, 信号の強さはパルスの密度である。


2.2 ニューラルネットワークの数理モデル

2.2.1 マカロックとピッツのモデル

NNの起源は1943年のマカロックとピッツの研究。

神経生理学者で外科医のマカロックは、チューリングの影響を受けて、思考の計算モデルを作ろうと考えた。

神童のピッツを共同研究者として、脳の論理処理の計算モデル(形式ニューロンと呼ばれる素子からなる回路)を考え出した。



形式ニューロン(左)と簡単なニューロン回路の例(右)

形式ニューロンには他の多数の形式ニューロンから0か1の信号 x_i が入る。重みを w_i として総入力 u を

$$u = \sum_i w_i x_i \quad (3.1)$$

とする。このニューロンの出力 z を

$$z = \theta(u+b) = h\left(\sum_i w_i x_i + b\right) \quad (3.3)$$

とする。ここで h はヘビサイドの階段関数:

$$h(u+b) = \begin{cases} 1 & (u \geq -b) \\ 0 & (u < -b) \end{cases} \quad (3.2)$$

入力 u を出力 z に変換する関数を活性化関数という。

図の右はNAND。NNでいかなる論理演算も可能。


2.2.2 ローゼンブラットのパーセプトロン

前節ではパラメータ w や b は固定値であった。

ローゼンブラットはパラメータ w や b を「問題の解を与えるように訓練する」という学習の概念を導入した。

つまり、図のようなNNに教師あり学習をさせる。

ローゼンブラットはこのようなNNをパーセプトロンと呼んだ。




3層からなるパーセプトロンの例

人工知能と呼ばれる研究分野を立ち上げたミンスキー(ローゼンブラットの高校の同級生)は、入力と出力からなる2層パーセプトロンではXORのような線形分離不可能問題は解けないことを示した。



これが一因となり60年代の終わりに第1次ニューラルネットブームが終焉した。

3層パーセプトロンならばXORを解ける。



線形分離できる例(OR, AND)とできない例(XOR)

出力層	出力	0	1	1	0
	入力	0	1	1	0
中間層	出力	0	0	1	0
	入力	0	0	1	0
入力層	出力	0	0	1	1
	入力	0	0	1	1




排他的論理和(XOR)を実現するネットワーク2

排他的論理和(XOR)を実現するネットワーク1

2.3 現在の階層型ニューラルネットワークの構造

図に階層ニューラルネットワークを示す。パーセプトロンの入出力は0, 1であったがNNでは実数値。




左はユニットの構造。右は4層順伝播型NNの例。
丸の中の変数は各ユニットの出力値を意味する。

出力と入力、入力と出力の関係はパーセプトロンと同じ。改めて書くと

$$u = \sum_i w_i x_i \quad (3.6)$$

$$z = h(u + b) = h\left(\sum_i w_i x_i + b\right) \quad (3.7)$$

パーセプトロンとの違いは入出力が実数になっていることと、活性化関数には連続関数が使われること。



シグモイド関数

2.4 深層学習ニューラルネットワークの登場

最近NNが大きな話題

ブレイクスルーのキーワードは深層学習


人工知能の中核技術になる勢い

これまでのNN

汎化能力(未学習のデータに正解する能力)が非常に低い

NNはいかなる問題も解けることが数学的に保証

NNはNAND回路を作る。NAND回路を用いればいかなる論理回路も構成できる。



汎化能力を高めるために多層化すると、ローカル・ミニマムに捕まって学習を継続できない

↓
NNの冬の時代

2006年にHintonらが深層ボルツマン・マシンに成功



2012年にHintonらが深層NNが画像認識で画期的な誤り率をたたき出す

↓
深層NNの時代到来


深層とは中間層の総数が大きいということ。

3. 学習とは

誤差逆伝播学習: 誤差(教師データと出力データの差)をゼロにする学習をする



2層NN
(hは恒等関数)



多項式補間のNN的表現
 $f(x) = A_0 + A_1 x + A_2 x^2 + \dots + A_n x^n$

出力ユニット入力: $u = \sum w_i x_i + b$

出力ユニット出力:

未知数は $w_1, w_2, \dots, w_n$ と b の $n+1$ 個.

学習方法を $v = t$ or $h\left(\sum_i w_i x_i + b\right) = t$

とすると, 必ずしも解けない.

簡単な例: 2入力のANDは, 3つの未知数 w_1, w_2, b に対して, 4つの入力がある.

$$x_1 = 0, x_2 = 0 \rightarrow 0 = h(b)$$

$$x_1 = 0, x_2 = 1 \rightarrow 0 = h(w_2 + b)$$

$$x_1 = 1, x_2 = 0 \rightarrow 0 = h(w_1 + b)$$

$$x_1 = 1, x_2 = 1 \rightarrow 1 = h(w_1 + w_2 + b)$$

h を恒等関数とすると, 上の3つの方程式から

$b = w_1 = w_2 = 0$ となり4番目の方程式を満足できない.


しかし, h を非線形関数であるヘビサイドのステップ関数とし, $b = -1.5$ とすると, $w_1 = w_2 = 1$ が解になる.

ニューロはどんな問題も解ける。

非線形回路である。

誤差逆伝播学習 (NNの理論ではこれが一番難しい)

入力層が第0層, 中間層が第1, 2, ..., N-1層, 出力層が第N層の場合に一般化すると



$n+1$ 層の j ユニットへの入力:

$$u_j^{(n+1)} = \sum_i w_{ji}^{(n)} v_i^{(n)} + \theta_j^{(n)}, \quad n = 0, 1, \dots, N-1$$

$n+1$ 層の j ユニットの出力:

$$v_j^{(n+1)} = h(u_j^{(n+1)}) = h\left(\sum_i w_{ji}^{(n)} v_i^{(n)} + \theta_j^{(n)}\right)$$

誤差関数:

$$E = \frac{1}{2} \sum_j (t_j - v_j^{(N)})^2$$

$$= \frac{1}{2} \sum_j \left(t_j - h\left(\sum_i w_{ji}^{(N-1)} v_i^{(N-1)} + \theta_j^{(N-1)}\right) \right)^2$$

$$\frac{\partial E}{\partial w_{ji}^{(N-1)}} = -(t_j - v_j^{(N)}) \frac{\partial v_j^{(N)}}{\partial w_{ji}^{(N-1)}}$$

$$\frac{\partial v_j^{(N)}}{\partial w_{ji}^{(N-1)}} = h'(u_j^{(N)}) v_i^{(N-1)}$$

したがって

$$\frac{\partial E}{\partial w_{ji}^{(N-1)}} = -(t_j^{(N)} - v_j^{(N)}) h'(u_j^{(N)}) v_i^{(N-1)}$$

同様に

$$\frac{\partial E}{\partial \theta_j^{(N-1)}} = -(t_j^{(N)} - v_j^{(N)}) h'(u_j^{(N)}) \cdot 1$$

誤差の定義と計算法:

$$\begin{aligned}\delta_j^{(N)} &= -\frac{\partial E}{\partial u_j^{(N)}} = -\frac{\partial E}{\partial v_j^{(N)}} \frac{\partial v_j^{(N)}}{\partial u_j^{(N)}} \\ &= (t_j - v_j^{(N)})h'(u_j^{(N)}) \\ \delta_j^{(n+1)} &= -\frac{\partial E}{\partial u_j^{(n+1)}} = -\frac{\partial E}{\partial v_j^{(n+1)}} \frac{\partial v_j^{(n+1)}}{\partial u_j^{(n+1)}} \\ &= -h'(u_j^{(n+1)}) \sum_k \frac{\partial E}{\partial u_k^{(n+2)}} \frac{\partial u_k^{(n+2)}}{\partial v_j^{(n+1)}} \\ &= h'(u_j^{(n+1)}) \sum_k \delta_k^{(n+2)} w_{kj}^{(n+2)}\end{aligned}$$

誤差 $\delta_j^{(n)}$ は上の階層から決まるこれが**誤差逆伝搬法**の名前の由来。

勾配の計算法:

$$\begin{aligned}\frac{\partial E}{\partial w_{ji}^{(n)}} &= \frac{\partial E}{\partial u_j^{(n+1)}} \frac{\partial u_j^{(n+1)}}{\partial w_{ji}^{(n)}} = -\delta_j^{(n+1)} v_i^{(n)} \\ \frac{\partial E}{\partial \theta_j^{(n)}} &= \frac{\partial E}{\partial u_j^{(n+1)}} \frac{\partial u_j^{(n+1)}}{\partial \theta_j^{(n)}} = -\delta_j^{(n+1)} \cdot 1\end{aligned}$$

最急降下法によるウェイト w_{ij} とオフセット θ_j の修正量:

$$\Delta w_{ji}^{(n)} = -\frac{\partial E}{\partial w_{ji}^{(n)}} \alpha \quad \Delta \theta_j^{(n)} = -\frac{\partial E}{\partial \theta_j^{(n)}} \beta$$

勾配は誤差逆伝搬法によらなくても**数値微分**でも遺伝子アルゴリズムでも可能であろう。

従来のNNの問題点と対策

汎化能力が低い、しかし多層化できない
十分に学習できない

シグモイド以外の活性化関数の導入

例えばReLU(Rectified Linear Unit)

前処理ネットワークの導入

自己符号化器 (Autoencoder)

畳み込みNN (Convolution NN)

学習し過ぎて過学習になる

学習の制限

正則化

ニューロには2回の冬の時代があった。

3回目の飛躍期に突入した。

ディープラーニング:

要するに中間層が多いこと


新しい構造の導入:

オートエンコーダ


コンボリューション

過学習防止

新しいアーキテクチャの導入:



自己符号化器 (Autoencoder)



ニューロン数:

入力層=出力層>中間層

学習:

教師データ=入力データ

中間層に圧縮されたデータ

ノイズが落ちる

自己符号化器の利用


ノイズ除去:

入力データにノイズありデータ, 教師データにノイズなしデータを与えて学習させると, ノイズ除去フィルタができる。

故障, 異常診断:

正常データで学習させた自己符号化器に異常データを見せると, 正常データを出力するので, 入力データと出力データの差を取ると, 異常が検知される。

畳み込みNN (Convolution NN、微分操作)



畳み込みニューラルネット

この構造を開発するヒントになったのは、動物の視覚野の構造である。

ヒューベルとウィーゼルの階層仮説

人間にはパターンを認識する高い能力が備わっている。

網膜で受け取られた視覚情報の電気信号は、画像としての平面構造を保ったまま、外側膝状体を経由して、1次視覚系に入力する。1次視覚系は後頭野にある。ここで、パターン認識プロセスの重要な第1段階が行われる。

1958年ヒューベルとウィーゼルは、猫の視覚野に特定の傾きをもつ線分を見せたときにだけ反応する細胞があることを発見した。

このような細胞は単純型細胞と複雑型細胞に大別され、これらの違いは図の受容野の概念で説明される


図(a)(b)の4つのケースそれぞれは、左の四角い領域(網膜)から視覚信号を受け取った際に、縦に並んだ4つのニューロンがどう変化するかを示す概念図である。

4つのうち上から2つ目のニューロンに注目する。

単純型細胞(a)では、パターンが灰色で塗りつぶされた領域にぴったり現れた時にのみニューロンが発火する。

(a)の下図では発火するが、上の図では発火しない。

複雑型細胞(b)はパターンがずれた時でも発火する。



(a) 単純型細胞、(b) 複雑型細胞。単純型細胞は、パターンの形状に対応した網膜型細胞とのみ結合を持つ。ヒューベルとウィーゼルの説では、複雑型細胞はそのような単純型細胞を束ねる形で実現している。

ヒューベルとウィーゼルの階層仮説によると、単純型細胞はパターン内の受容野とのみ結合している。刺激が受容野とぴったりあった時に最も大きく反応する。

(c)の3層目のニューロンは複雑型細胞で単純型細胞を束ねている。

したがって複雑型細胞は網膜上のより広い範囲にパターンがあれば反応する。

階層仮説が大きなヒントとなって生まれたのが畳み込みニューラルネットワーク(convolutional network CNN)である。

CNNの起源は福島邦彦のネオコグニトロン(1979)に遡る。1989年にカルカンのグループが同じネットワークに誤差逆伝播法を導入して高い性能を実現した(LeNet)。

ニューラルネットと畳み込み

畳み込みニューラルネットは2種類の層からなる。

1つ目の層は単純型細胞からなり図の(a)のように全体を覆う。(a)の右図のように次層と結合されている。どこにパターンが現れても次層のユニットが活性化する。

1層と2層の間はスパースな結合である。

パターンの現れる位置で認識能力が変わらないためには、結合がすべて同じ重みを持っていればよい。

結合の多さにもかかわらずパラメータ数は少ない。

畳み込み層には重みのスパース化と共有という2つの正規化が課せられていると看做せる。

プーリング層(複維型細胞、積分操作)

複維型細胞に対応する**プーリング層** (pooling layer) の説明をする。

プーリング層の役割は単純型細胞の出力を合算して入力位置の平行移動に対して**ロバスト**にすること。

$W \times W \times K$ 入力画像 $z_{i,j,k}^{(l-1)}$ の各チャンネルに対し、各画素位置 (i,j) を中心とした $H \times H$ の領域 P_{ij} を考える。

ただし画像はパディングしておき、どの点に対しても P_{ij} の領域を取れるようにしておく。

P_{ij} 中の画素から、**その領域での代表的な値** $u_{i,j}^{(l)}$ を決定する。

最大プーリングでは、領域中の**最大の画素値**を代表値とする。

$$u_{ijk}^{(l)} = \max_{(p,q) \in P_{ij}} z_{pqk}^{(l-1)}$$

最大プーリング以外にも、**平均プーリング**：

$$u_{ijk}^{(l)} = \frac{1}{H^2} \sum_{(p,q) \in P_{ij}} z_{pqk}^{(l-1)}$$

この2つのプーリングを拡張した方法として、 L^p **プーリング**：

$$u_{ijk}^{(l)} = \left(\frac{1}{H^2} \sum_{(p,q) \in P_{ij}} \left(z_{pqk}^{(l-1)} \right)^p \right)^{\frac{1}{p}}$$


$P=1$ の場合は明らかに平均プーリングになるが、対極の $P \rightarrow \infty$ では、最大プーリングになる。(証明省略)

確率的プーリングというものもある。

プーリング層の役割は畳み込み層の出力を束ねるだけだから重み学習はしない。学習**中**も**プーリングの式は変更されない**。

ネットワーク構造

典型的なCNNの例を図に示す(オックスフォード)。



VGGの一例。緑は入力層、オレンジ色は畳み込み層、青は**マックスプーリング層**。灰色は全結合層、そして**赤は出力のソフトマックス層**。数字は各畳み込み層のフィルタの幅。

学習済みモデルと転移学習

ImageNetなどの大きなデータで学習したモデルは、他の機械学習とは比較にならないほどの**高い画像分類性能**を達成できる。

しかし多層のCNNを用いた**自然画像の学習**には**多くのコストと計算時間**を要する。

もしも、学習済のモデルがImageNetデータの分類以外には全く役立たないならば、コストが高すぎて、魅力が半減する。

しかし、**ニューラルネット**には**高い汎化性能**があり、深いネットワーク構造では、**中間層にさまざまな特徴量を獲得**していると期待される。

そこで、学習済のモデルの出力側の層を取り除いて、**中間層からの出力を入力画像の表現**として用いることが考えられる。

出力に近い側は出力層に設定した学習タスクに強く影響を受けていて、他のタスクへの応用に向かない。

出力層だけを置き換えて他のタスクのために学習し直す方法も用いられる。

学習済みパラメータが初期値となって、**学習がスムーズに進行**する。


この方法を**転移学習**という。

CNNはどのようにパターンを捉えているのか

CNNの**高い学習能力**の詳細は**多く分かっていない**。しかし、**CNNの中を覗き見る技術**はさまざま開発されている。

図の(1)、(2)、(3)はそれぞれVGG16のある特定の画像で、(1)から(3)の順に出力寄りから入力寄りの順に並んでいる。

これを見ると、**低層から高次の層に行くに連れ**、各フィルタがより**複雑なパターン**を捉えている。ただ、高次の層でのパターンは**直感的に理解**できるものでない。



図の(a)から(f)は、出力層から選んだ6個のユニットに対応した画像である。

(a)三葉虫, (b)シベリアンハスキー, (c)シマウマ, (d)タクシー, (e)図書館, (f)エスプレッソである。

ランダムノイズを初期値として作成した入力画像である。99.9%という高い確率で、各カテゴリに分類される。

人間がこの画像を見ても、全く認識できない。

ノイズに対するこの謎めいた挙動はadversarial examplesという現象と類似のもので、現在でも活発に研究されている。

正則化

過学習の防止： 過剰な自由度を除く

重み減衰 (Weight Decay) 項を導入：

$$E_{WD}(\mathbf{w}) = E(\mathbf{w}) + \lambda \mathbf{w}^T \mathbf{w} = \text{minimum}$$

誤差関数 $E(\mathbf{w})$ だけでなく、 $\mathbf{w}^T \mathbf{w}$ も最小化されるので、不要な重みは出来るだけゼロに近づく。

実際的な方法： 訓練データを学習データと評価データに分け、評価データが増加に転じた時点で学習をやめる。

5. リカレントニューラルネットワークRNN

時間が関係しない問題：

0から9の数字を示してどの数字かの判断を求める。

時間が関係する問題：


0から9の一連の数字を示して、次はどの数字が出るかを当てる。

時間(文脈)が関係する問題はいろいろある。

株価の変動のような時系列


音声認識、言語理解、翻訳などの言語問題
破損した絵画の修復(空間的な文脈)

過去なし 過去あり(再帰型ニューラルネットワーク RNN)




$$o = f_o(W_{oh} \cdot h) \quad o' = f_o(W_{oh} \cdot h')$$


$$h = f_h(W_{hi} \cdot i) \quad h' = f_h(W_{hi} \cdot i' + W_{hh} \cdot h^{t-1})$$



出力層から隠れ層、入力から入力などいろんな帰還がある。



入力から入力に帰還する場合



helloの推定(<https://qiita.com/KojiOhki/items/397f157342e0def06a9b>)

6. 深層学習ニューロの応用

船舶性能の場合

Wake分布の推定

推力減少率 t , η_R の推定

(t = 曳航抵抗 / プロペラ推力, η_R = 船後効率 / 単独効率)

推進性能の最適化

抵抗増加などの荒天中の推進性能

操船自動化

他船の意図

不規則波の時系列

7. 終わりに...学習の手引き

東京女子大学の浅川伸一先生から頂いた情報

Summary of ImageNet




Figure: イメージネットの優勝チームの成績年次変化

フレームワーク毎の GitHub 星数




Figure: フレームワーク毎の GitHub 星数の推移 ¹
<http://jforditorres.org/deep-learning-frameworks/>

フレームワーク毎の GitHub 星数 (2)




Figure: フレームワーク毎の GitHub 星数の推移 without TensorFlow and Theano

日本人向けの独学用教材としては

MathWoksのビデオ・Webセミナー

MATLAB によるディープ・ラーニング

<https://jp.mathworks.com/videos/deep-learning-with-matlab-119998.html>

MathWorks社の製品を導入することを前提にしているが、よくまとまっていて、**非常に分かり易い**。

Michael Nielsen

ニューラルネットワークと深層学習

オンライン書籍 (日本語訳)

https://nnadl-jp.github.io/nnadl_site_ja/ 第1-4章

<http://yusuke-ujitoko.hatenablog.com/entry/2017/02/18/235231> 第5-6章

日本語に読み易く翻訳されている。丁寧に書かれているので、**時間を掛けられる人が、腰を据えて取り組む**のに向いている。

瀧正人

これならわかる深層学習

講談社、2017

深層ニューラルネットワークの理論を包括的に、分かり易く説明している。深く理解したい人には最適と思うが、応用についての解説は十分ではないと思われる。この本を読んだからと言ってすぐにコーディングできたり、すぐにライブラリを活用できるとは思えないが、**研究開発者の必読書**であることに間違いない。

Francois Chollet

DEEP LEARNING with Python

Manning Publications, 2018

深層学習ニューロの使い方の解説書である。Keras(MITのライセンス)をframework(基盤、ライブラリ)としおり、使用言語はPythonである。**難しい式は皆無で、アプリケーション作成方法が詳しく解説されている。すぐに深層学習ニューロを応用したい人には最適**といってよからう。深層学習ニューロのほぼ全般にわたり解説しているが、Convolution NN(画像)とRecurrent NN(言語、時系列)が中心でAutoEncoderには触れていない。

磯蘭水、藤永奈保子、鈴木悠(翻訳)(Jason R. Briggs)

楽しいプログラミング Pythonではじめよう!

(Snake Wrangling For Kids Learning to Program with Python)

オーム社

https://www.utrgv.edu/cstem/_files/documents/snake-wrangling.pdf

深層学習NN学習の言語としては**Python**が必須である。このテキストは親が子供にプログラミングを教える際のテキストとして書かれているので、**大変分かり易い**。

MOOC (Massive Open Online Courses, 大規模公開オンライン講座)

例えば、fast.ai のDeep Learning Part 1: Practical Deep Learning for Codersがある。ビデオレクチャで、7レッスンからなる。英語の発音もクリアでとてもよい教材と思う。Pytorchをframework(基盤、ライブラリ)としている。実際にPCを動かしながら、さらに補助教材を読みながら聞かないと理解できないと思われる。

8. 終わりに...AIで人類は進歩する?

甚だ疑問です!

AIの本質は人の知識、知見を機械に移すこと。

要するに既存の知識を機械に与えることであって、新しい知識を生み出すものではない。

答えの分かっている問題を機械に解かせるのであって、答えの分かっている問題は人間が解く。

碁や将棋で人間を負かすのは、そろばんの名手が計算機にかなわないのと同じでいわば当たり前。

AIは人間のエキスパート、熟練者の経験をベースにする。人間は競争し合って進歩して行くが、人間を介さないAI同士の競合はどうやって実現し進歩するか?

我が家には犬が1匹います。8歳のミニチュア・ダックスフントです。

この犬は横着で自力で散歩をしない。仕方がないから車イスに乗せて散歩をします。

家の少し前で車椅子から降ろすと、一目散で家に帰る。下り坂なので、家の方向は坂を下る方向と覚えている。

家を通り過ぎて放すと、家から遠ざかる方向にダッシュする。おかしいことに気づくとその場にうずくまる。

要するに、誤りを気づく能力はあるが、問題解決能力はない。人間のように柔軟に対処できない。

AIに人間と同じような柔軟性を持たせるのは難しい？

AIの進歩のお陰で、英語を知らなくても外国人と意思疎通できるようになった。

そうならば、英語を学ぶ必要がなくなった？

この答えは、イエスでありノーである。

意思疎通という意味では、ほとんど要らない。

しかし、外国語を学ぶことは外国の文化を学ぶことです。また、頭を駆使することで頭は柔軟になる。

この問題は、柔道や剣道を学ぶのと同じです。大学で学ぶのも同じといって良いかも知れない。

要するに、柔道や剣道を学べば、体が丈夫になります。 unnecessaryなことを学べば、頭が丈夫になります。友人が出来るかも知れません。

AIは人間のできないことをできる？

AIには大量のデータが必要です。大量のデータから平均像を浮かび上がらせることで、AIは統計学の一手法のように思います。

人間には少量のデータから真実を浮かび上がらせる能力があるようです。ニュートンの重力の法則、アインシュタインの相対性理論は正にそうです。そこにあるのは演繹能力とひらめきです。これこそが人間の能力の根幹かも知れません。

人間の能力

人間の脳力は「経験」と「演繹」と「学習」と「ひらめき」からなっています。

ニューロがやるのは、「経験」と「学習」の部分です。

人間は「創造」と「模倣」ができます。機械にできるのは「人間の模倣」であり、「創造」と「模倣」は次元が違います。

機械は人間の作ったものですから、機械のできることは人間のできることと言えないでしょうか？

そう言う意味で人間が機械に負けることは論理的にあり得ないのです。


人間は空を飛べる。間違いでしょうか？

これは正しい。人間は自らが作り出した飛行機により空を飛べるから、空を飛べると言っても間違いではないでしょう。


AIは碁や将棋で人間を負かす？

これは間違い。人間はAIに負けるのではなく、AIに碁や将棋を教えた人間に負けたに過ぎない。

人相術



迷子のサポート



終わり

Thank you for your attention!