人工知能の実用化に関する一考察

A Study on Practical Use of Artificial Intelligence.

高 田 茂 樹

The purpose of this research paper is to demonstrate the ease of using artificial intelligence in the light of the recent popularity of tertiary artificial intelligence. In this paper, I try to use artificial intelligence libraries that are open to the public. Additionally, I examine the prediction accuracy of machine learning, verify the recognition capability of deep learning, and discuss the necessary computer skills to use artificial intelligence. As a result of these examinations, machine learning was found to bring a rate of correct answers of more than 50%, and deep learning scored a high recognition rate. However, it is not easy for people who have never written a computer program to use artificial intelligence at this stage.

Shigeki Takada

JEL：C87, C88
キーワード：人工知能、機械学習、深層学習
Keywords：artificial intelligence, machine learning, deep learning

1. はじめに

最近、人工知能（AI）についての話題が絶えない。将棋のプロ棋士とコンピュータソフトが対決する「第 1 期電王戦」（主催・ドワンゴ、日本将棋連盟）が 2017 年 4 月 9 日に開幕、「第 2 期電王戦」が 5 月 20 日に行われ、コンピュータソフト「PONANZA（ポナンザ）」が佐藤天彦名人（29）を破り、2 連勝を果たした。囲碁界では 2017 年 5 月 27 日、囲碁 AI「アルファ碁」がトッププロ棋士に 3 連勝したことで、人工知能の進歩が大きなニュースになった（日本経済新聞, 2017a）。

人工知能の活躍は、将棋の世界だけの話ではない。自動車の自動運転技術においても、その技術が大きく関わっている。人工知能を自動車に搭載することで、事故の発生件数を 37%減少させることができるという予測を、自動運転や自動運行サービスを提供する国外企業「NAUTO」が明らかにした。

また、採用支援サービスを提供する株式会社タレントアンドアセスメントは、開発を進めている人工知能を活用した採用面接サービス「SHaiN」（シャイン）の商品説明会を開催している。人工知能の導入により、従来の採用面接に費やしていた人件費や時間を削減できるとともに、人間による採用面接で課題視されてきた評価のばらつきを改善し、採用基準の統一を可能にすることができる（CNET, 2017）。

前述の人工知能の躍進を見ると、人工知能は近年、人間社会に急速に進出してきたと言えるだろう。しかし、その研究の歴史は古く、第一次人工知能ブームは 1950 年代後半〜1960 年代に起きている。そして、第二次人工知能ブームは 1980 年代〜90 年代、最後に現在は第三次人工知能ブームと呼ばれ、2000 年代から始まったと言われている。第一次人工知能ブームでは、コンピュータによる「推論」や「探索」が可能となり、特定の問題に対して解を提示できるまでに至った。しかし、当時の人工知能（AI）では、迷路の解き方や定理の証明のような単純な仮説の問題を扱うことはできても、様々な要因が絡み合っているような現実社会の課題を解くことはできないことが明らかになったことで、そのブームは沈静化した。第二次人工知能ブームにおいては、様々な情報の内容をコンピュータが認識できるよう表現するようになり、人工知能活用への期待が高まったが、世にある膨大な情報すべてを人間がコンピュータ向けに記述することは困難であったため、その活用は限定的となりブームも一旦沈静化する結果となった（総務省,2016）。第三次のブームにおける人工知能（AI）は、大きく 2 つ、狭義の機械学習（machine learning）と深層学習（deep learning）に分けられる。狭義の機械学習においては、分析にあたり注目すべき要素（特徴量）は人間が抽出しなければならないが、特徴量間の関係の記述はコンピュータが行うようになり、コンピュータの性能向上や利用可能なデータの増加もあいまって実用性が高まった。ディープラーニングにおいては、学

習用のサンプルデータを与えれば特徴量の抽出までもコンピュータが行うようになった（総務省,2016）。今や人工知能は研究者や公的な企業のみが扱うことのできるものではなくなった。Google 社は人工知能を一般人にも利用できるように、同社が開発し改良を重ねた API、ライブラリを公開している。すでに人工知能はより私たちの身近な場所に存在するものであると言える。そこで本稿では、人工知能をどの程度簡単に使うことができるのかを、一般に公開されている人工知能ライブラリを用いて試行することにした。具体的には、機械学習の予測精度の検証、ディープラーニングの認識能力の確認を行い、その結果と人工知能を使うために必要なコンピュータスキルについて考察を述べたい。

2. 第三次人工知能ブームを支える技術的背景

2.1 モバイル通信技術の急速な発展

モバイル通信の規格は表 1 のように約 10 年毎に通信速度の大きな向上がもたらされてきた。その速度向上を成し遂げる背景には、半導体の進化によって得られた計算能力の向上、通信関連企業の努力によってもたらされた新たな通信技術の開発と革新、法制度上の規制改革によって開放されたサービス通信帯域の確保などができたからである。

表 1　モバイル通信方式の規格の推移

1G	第1世代移動通信規格	アナログ方式	1979年頃から
2G	第2世代移動通信規格	デジタル方式	1991年頃から
3G	第3世代移動通信規格	約14Mbpsの通信速度	2001年頃から
3.9G	第3.9世代移動通信規格	～100Mbpsの高速通信	2010年頃から
4G	第4世代移動通信規格	100Mbps以上の超高速通信	2017年8月以降予定
5G	第5世代移動通信規格	1Gbps以上の超高速通信	2020年以降予定

近い将来、5G のモバイル通信サービスが提供されると、各家庭などに多く導入済みのインターネット回線（光、CATV、ADSL など）の通信速度を上回り、移動型デバイスのみで快適な通信環境を実現することができる。

人工知能を本格的に活用するにはリアルタイムでの多くの情報交換が必要になるため、高速で帯域が広く安定したモバイル通信技術が人工知能の発展と利用に大きく貢献することは間違いないだろう。

2.2 人工知能が求める計算機能力の高速化

計算機能力の高速化に欠かせないのが GPU コンピューティングである。GPU コンピューティングとは、コンピュータでの数値計算において GPU を利用することである。GPU とは Graphics Processing Unit の略称で、パソコンの画像処理を行う主な半導体部品の一つである。高速処理ができる VRAM（ビデオメモリ）と併設され、グラフィック処理に特化した演算ユニットが多数集まった構造を持っている。各演算ユニットの構造は単純で、機能的には CPU より限定されているが、複数の演算ユニットを同時に使い、大量のデータを同時に並列処理することができる能力がある。並列処理能力を表すコアについては、CPU の場合はデュアルコア、クアッドコアのような表現が使われるが、GPU の仕様ではこのコアに相当するものが数千の単位で構成されている。そのため、アプリケーションの連続的な処理部分を CPU により、並列的な演算部分を GPU により計算させるという共同演算処理で、CPU 単体のみで計算させる場合より圧倒的に高速で演算することができるようになった。この技術が人工知能の進歩に大きく貢献している。

3. 機械学習（machine learning）を用いた株価予測

3.1 機械学習概要

機械学習とは、コンピュータを用いて特定のデータを解析した結果から特徴となる傾向を見つけ出し、その傾向を元に判断や予測を行うためのアルゴリズムを用いた訓練を行うデータ解析手法のことである。機械学習の分野では、すでにデファクトスタンダードとして完成度の高い学習用ライブラリが提供されている。ライブラリには分類、回帰、クラスタリング、次元削減などの分析手法が含まれている。

機械学習の基本的な手順は、1. データの入手、2. データ前処理、3. 手法の選択、4. 説明変数の選択、5. モデルの学習、6. モデルの評価、7. 調整となる。

3.2 scikit-learn

本稿では、プログラミング言語 Python と Python のオープンソースライブラリとして機械学習の分野で多くの研究者から支持されている scikit-learn（サイキット・ラーン）を用いて試行を行った。Python を使用する利点は、NumPy と SciPy という数値計算ライブラリ、pandas というデータフレームライブラリ、matplotlib というグラフ描画ライブラリを利用できることである。 scikit-learn には、分類や回帰、クラスタリングなどの機能が実装され、さらに様々な評価尺度やクロスバリデーション、パラメータのグリッドサーチなどの機能が含まれている。scikit-learn で出来ることについては、本稿末付録（図 9）を参照のこととする。

3.3 株価予測試行の流れ

実際に scikit-learn を使用して株価予測を試行した手順と結果について報告する。試行は 2 種類のプラットフォームで行うことにし、Windows ノート PC（Windows7、8GB RAM、SSD）に Anaconda3（開発環境管理ソフト）を使い Python3.6 の環境、および Macbook Air（MacOS 10.12.3、4GB RAM, SSD）に Homebrew（MacOS 用パッケージマネージャー）を使い Python2.7 の環境を構築して行った。

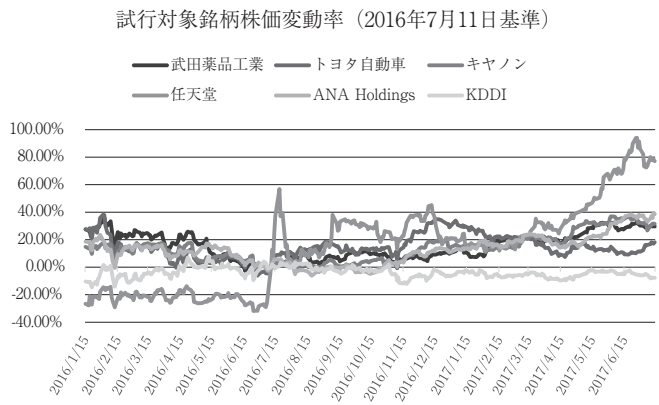
3.3.1 データの入手

本稿の試行で使用したデータは、株価データサイト “k-db.com” から日足データを 2017 年 7 月 14 日から遡って直近 250 日分と 2016 年のデータを CSV 形式でダウンロードした後、Excel を用いてデータ結合を行い 2016 年 1 月 4 日から 2017 年 7 月 14 日までの時系列データに加工編集した。入手したデータには日付、始値、高値、安値、終値、出来高、売買代金が含まれており、各項目名が日本語で入力されていたため、文字コード処理のエラーを回避するため日本語標記を英語表記に変更して、Date、Open、High、Low、Close、Volume、Trading Value とした。

株価予測試行対象銘柄（目的変数）としては、武田薬品工業、トヨタ自動車、

キヤノン、任天堂、ANA ホールディングス、KDDI を選択した。説明変数に用いた銘柄は上場 ETF の中から複数を選択した。これら予測対象の 6 銘柄を選択した理由は、企業規模が大きく、日々の出来高が多く、任天堂以外は図 1 の変動率チャートが示す通り、予測に使用したデータ期間の株価の値動きが標準偏差の± 3 倍以内で安定して推移していると判断したためである。任天堂は 2016 年 7 月に、世界的に話題となったスマートフォンアプリが配信されたことをきっかけとして株価が急騰し、その後の人気ゲーム機発売などの好材料により株価の上昇が続いているため、株価変動が大きいデータについても検証したいと思ったからである。説明変数として上場 ETF を選択した理由は、指標との連動性が高く、株式銘柄と同様に毎日価格が変動するため、相関性の高いものを見つけやすいと期待したからである。

図 1　試行対象株価の変動率推移



3.3.2　データ前処理

機械学習に使用するデータの前処理としては、ダウンロードしてきた別々のファイルになっている時系列データを一つのファイルに統合する必要がある。学習には各取引日の終値を使用することにし、目的変数の銘柄のデータに、説明変数で使用する各 EFT の終値と前日からの変動率を日付でマッチさせて

追加したものに加工した後、CSV ファイルとして保存する作業が必要である。データの中で終値データが空白になっている場合は、前日のデータを代わりに入れて変動率は 0 にした。この作業は Excel を使用した手作業でもできるが、データ量とファイル数が多いため Python でプログラムを作成してデータ前処理を実行した。

3.3.3　手法の選択

機械学習の手法は “Random Forest” を使用した。“Random Forest” は決定木を複数組み合わせて、各決定木の予測結果を多数決することによって結果を得る決定木ベースの集団学習アルゴリズムを取り入れたものである。その特徴は、数千の変数など大きなデータに対して効率よく処理され、どの変数が分類に対して重要なのかを計算して与えてくれることである。そのアルゴリズムを簡単に述べると、“データをランダムに抽出する” と “決定木を成長させる” という作業を指定回数繰り返し、予測結果を多数決して分類ラベルを決定するというものである。

3.3.4　実行パラメータと説明変数の選択

“Random Forest” に指定する決定木の数はデータ数と同じにした。試行結果から得られた説明変数の重要度（付録図 10 が出力サンプル）を参考に、重要度が安定して高い ETF（表 2）を採用した。

3.3.5　モデルの学習と予測

モデル学習の期間については、数年分のデータであっても入手できるため、期間を長くすることも視野に入れ、期間を変更して学習結果の正解率を比較した。しかし、明確な差は見られなかったため、構築するモデルは市場取引日の約 1 年分に当たる 250 日を採用し、過去の 249 日分を学習データとして、250 日目を予測することにした。モデル学習は、前処理したデータを評価用テストデータと学習用トレーニングデータに分け、データ期間中の最新日データを評

表 2　説明変数に使用した ETF 銘柄一覧

No	ETF銘柄
1309	上海株式指数・上証50連動型上場投資信託
1321	日経225連動型上場投資信託
1322	上場インデックスファンド中国A株（パンダ）CSI300
1323	NEXT FUNDS 南アフリカ株式指数・FTSE/JSE Africa Top40連動型上場投信
1326	SPDRゴールド・シェア
1543	純パラジウム上場信託（現物国内保管型）
1546	NEXT FUNDS ダウ・ジョーンズ工業株30種平均株価連動型上場投信
1548	上場インデックスファンド中国H株（ハンセン中国企業株）
1566	上場インデックスファンド新興国債券
1590	iシェアーズ 米国リート・不動産株ETF（ダウ・ジョーンズ米国不動産）
1633	NEXT FUNDS 不動産（TOPIX-17）上場投信
1671	WTI原油価格連動型上場投信
1678	NEXT FUNDS インド株式指数・Nifty 50連動型上場投信
1680	上場インデックスファンド海外先進国株式（MSCI-KOKUSAI）
1698	上場インデックスファンド日本高配当（東証配当フォーカス100）

価用テストデータにした。学習用トレーニングデータは、x 日の終値株価の前日比率を説明変数に、x+1 日の終値株価の騰落を目的変数に入れ、x+1 日の株価が上昇していれば、“+1” を、下落していれば “-1” を入れるという学習方法にした。

本稿の試行では、2017 年 7 月 14 日から 20 営業日ずつ等間隔に遡って 6 月 16 日、5 月 19 日、4 月 18 日、3 月 21 日、2 月 20 日、1 月 23 日をデータ期間の最新日とした 7 回分の試行用データ（全て期間最新日から遡って 250 日分）を用意して行い、目的変数として選択した複数銘柄の株価予測精度を検証した。例えば、1 月 23 日の株価予測をする場合は、1 月 22 日以前の説明変数である ETF データを用いて予測をし、結果が 1 の場合は株価上昇、-1 の場合は株価下落というわかりやすい推定結果が得られることになる。結果には騰落の推定、説明変数の重要度に加えて、交差検証法（学習用データを 5 分割してその中の一つをテスト用データに、残りを教師用データとして使い、テスト用データを変更しながら 5 回繰返す検証）から得られた学習結果の正解率とその平均値も出力されるようにした。

3.3.6　モデルの評価

本稿モデルの交差検証法による学習結果の正解率では、表 3 のように全平均が 51.7%、銘柄別平均で最も高かったのはトヨタ自動車の 54.1%、対象日別平均で最も高かったのは 6 月 16 日の 54.2%であった。個別結果では、1 月 23 日の ANA ホールディングスの正解率の低さが目立っているが、それ以外では著しい差は見られなかった。

表 3　機械学習結果の正解率

試行対象日	1/23	2/20	3/21	4/18	5/19	6/16	7/14	平均
武田薬品工業	47.2%	47.5%	53.2%	56.1%	56.1%	56.5%	50.0%	52.4%
トヨタ自動車	52.6%	54.9%	51.3%	57.3%	51.2%	58.9%	52.4%	54.1%
キヤノン	45.1%	49.2%	48.4%	52.4%	55.7%	53.6%	47.6%	50.3%
任天堂	58.2%	58.5%	54.9%	52.4%	51.2%	54.1%	51.6%	54.4%
ANA Holdings	37.4%	45.1%	49.6%	54.5%	50.8%	52.9%	54.5%	49.2%
KDDI	51.7%	47.1%	52.4%	48.4%	50.5%	49.3%	50.0%	49.9%
平均	48.7%	50.4%	51.6%	53.5%	52.6%	54.2%	51.0%	51.7%

試行対象日別に、各銘柄の実際の株価騰落と機械学習の予測結果を照らし合わせた正解率（表 4）では、銘柄別平均で最も高かったのはトヨタ自動車の 85.7%、対象日別平均で最も高かったのは 1 月 23 日、5 月 19 日、6 月 16 日が同率の 83.3%であり、全体の平均より高い結果が得られた。

表 4　人工知能が出した予測と実騰落の正解率

試行対象日	1/23	2/20	3/21	4/18	5/19	6/16	7/14	正解率
武田薬品工業	○	○	○	X	○	○	X	71.4%
トヨタ自動車	○	X	○	○	○	○	○	85.7%
キヤノン	○	X	X	X	○	○	X	42.9%
任天堂	○	○	X	X	○	X	X	42.9%
ANA Holdings	X	X	○	X	○	○	X	42.9%
KDDI	○	X	○	X	X	○	X	42.9%
正解率	83.3%	33.3%	66.7%	16.7%	83.3%	83.3%	16.7%	54.8%

この結果から、銘柄による正解率のばらつき、試行対象日によるばらつきがあるように見えるが、無作為に選んだ銘柄や試行対象日ではないため、結果のばらつきについての結論は今後の課題としたい。

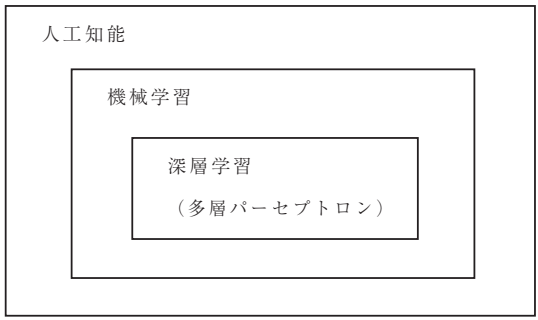
3.3.7　調整

本稿の試行では、説明変数として使っている ETF や試行対象日を変えながら正解率の向上を試みたが、いずれの結果においても平均 50%を大きく上回ることはなかった。さらに正解率を高めるには説明変数の変更、株価銘柄の変更など取組むべき課題はまだ多く残されている。今回は学習期間を 250 日分のデータに固定して試行したが、学習期間の増減、銘柄ごとに期間を変えるなどベターを目指すためのパラメータの組合せは無数にあり、次節で紹介する深層学習による試行も今後は試みたい。結果的に、機械学習だけでは正解率を上げるための試行錯誤をかなり繰り返して特徴量を見つけ出す必要があり、正解率を上げるには限界があるのではないかと感じた。

4. 深層学習（deep learning）を用いた画像認識の試行

4.1　ディープラーニング概要

図 2　ディープラーニングと人工知能の関係図



ディープラーニングとは、図 2 のような位置づけの人工知能技術であり、機械学習の手法の一つとして現在最も注目されている研究分野でもある。機械学習とディープラーニングの違いは、機械学習では人が学習モデルの特徴を定義して、分類方法を教えるのに対して、ディープラーニングでは人工知能が学習したデータから特徴を見つけて定義を作りながら分類方法そのものを自ら学習

してくれることである。

機械学習の一つであるニューラルネットワーク（図 3）は 1940 年代から研究されている、生物の脳神経細胞をモデルとしたアルゴリズムのことで、入力層、隠れ層、出力層という層（ニューロン）を持ち、それぞれの層は複数のノードがエッジで結ばれる構造になっている。このニューラルネットワークの隠れ層内を 2 層以上のネットワーク構造にしたものがディープラーニング（図 4）と呼ばれている。

図 3　ニューラルネットワークのニューロン

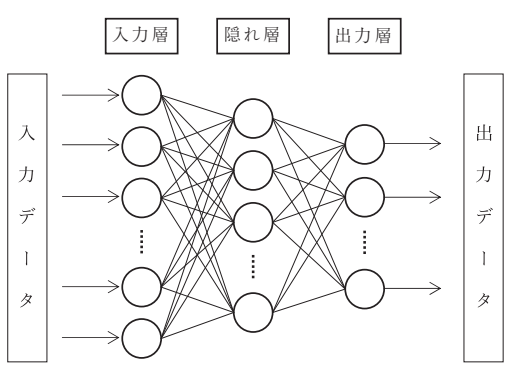
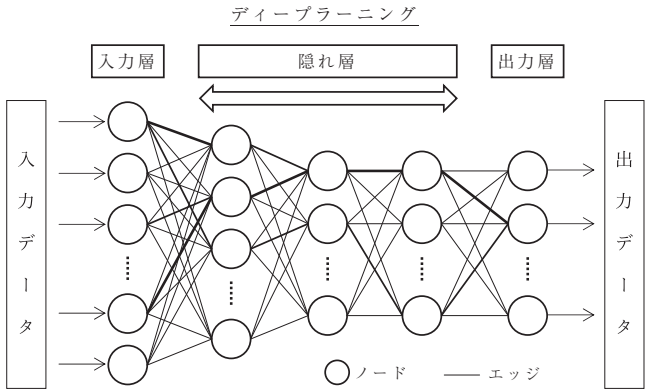


図 4　ディープラーニングのニューロン



各ノードの値は、結ばれた前層のノードの値、結ばれたエッジの重み、層の活性化関数から計算される。各層を結ぶエッジは重み（図 4 では線の太さ）を持つことができ、与えられたデータを細かく分類して、正解と不正解の判断をする試行錯誤を繰返し、正確が出る確率を上げるためにエッジの重みとなる特徴量を調整する。ニューラルネットワークではエッジの重みを教えるのは人間であったことに対して、ディープラーニングではエッジの重みを機械自らが見つけ出すことがその特徴である。

4.2 TensorFlow

“TensorFlow” とは、2015 年 11 月に Google が、Apache 2.0 のオープンソース・ライセンスの元でオープンソースソフトウェアとして公開した機械学習向けのライブラリである。“TensorFlow” は他の領域でも適用可能な汎用性が十分にあり、異なるデバイス、システム上で、ほぼ変更なしに、deep learning 用学習と推定のアルゴリズムなど多種多様なアルゴリズムを実行できる。

4.3 画像認識の試行

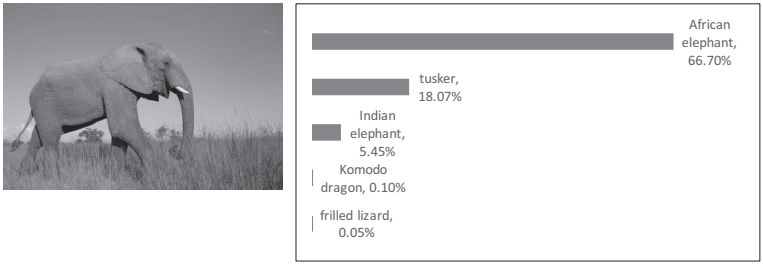
本稿では、ディープラーニングの認識能力を簡単に活用することを目的として、“TensorFlow” が提供している学習済み画像認識モデルのライブラリを用いて、複数の画像の認識を試みた。試行で使用した画像は pixabay のサイトにある著作権フリーの素材の中から動物の写真などを選択した。画像の選択で注意したことは、まず画像の縦横サイズが同じくらいのものを選んだことである。これは基準をできるだけ同じにして、サイズの違いによる認識度の違いを極力取り除きたかったためである。さらに被写体の向きが違うものを選んだことである。これは人工知能が、画像中のどの部分に特徴量の重みを持たせて認識しているかを見つけることができればと思ったためである。

認識の実行はコマンドを入力して、Python で書かれたプログラムにパラメータとして画像ファイルを渡し、被写体の種類とその確率が出力されるものである。次に、試行結果の一部を紹介する。

象の写真（図 5）を認識させてみた結果では、66.7%の確率でアフリカ像だ

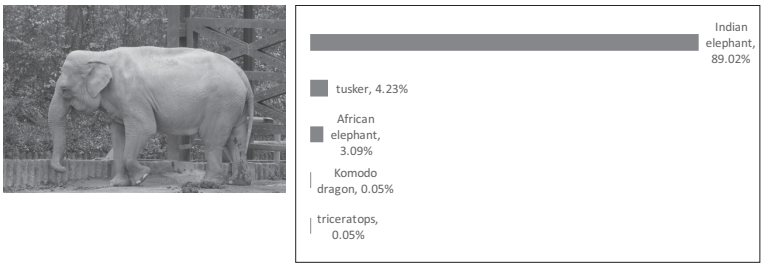
と判断している。その他に 18.07%の確率で牙の生えた動物と判断し、インド象の確率が 5.45%という認識を出した。この結果から、形状や色の他に「牙」を特徴量の重みとして採用していると推測できる。

図 5　象の写真 1 の認識結果



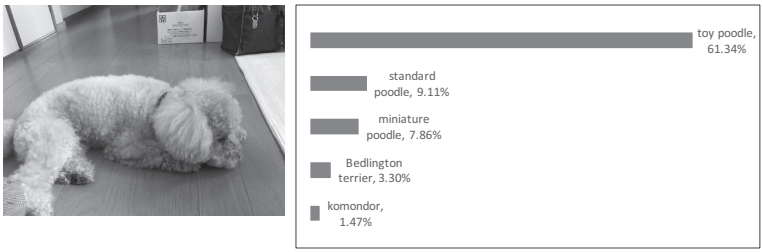
別の象の写真（図 6）を認識させてみた結果では、89.02%の確率でインド像だと判断している。この写真には牙は写っていないと思われるが、4.23%の確率で牙の生えた動物と判断し、アフリカ象の確率が 3.09%という認識を出した。この結果からも、図 5 と同様に「牙」を特徴量の重みとして採用していると推測できる。

図 6　象の写真 2 の認識結果



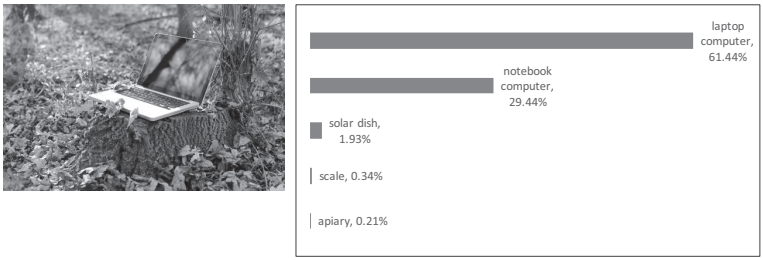
犬の写真（図 7）を認識させてみた結果では、61.34%の確率でトイプードルだと判断している。その他に 9.11%の確率でプードルと判断し、ミニチュアプードルの確率が 7.86%という認識を出した。この結果から、顔や姿全体の特徴がわかりにくい写真でも、耳の形状、毛の色や状態を特徴量の重みとして採用していると推測できる。

図 7　犬の写真の認識結果



ノートパソコンの写真（図 8）を認識させてみた結果では、61.44%の確率でラップトップコンピュータだと判断している。その他に 29.44%の確率でノート型コンピュータと判断し、太陽光パネルの確率が 1.93%という認識を出した。この結果から、落ち葉、木の幹、液晶画面に写り込んでいる要素などに影響されることなく、認識すべき対象が写真全体の中のどの部分であるかを把握し、その形状や色、キーボードの要素を特徴量の重みとして採用していると推測できる。

図 8　ノートパソコンの写真の認識結果



今回使用した画像認識モデルのライブラリによる認識結果は、付録図 11 のような形式で得られる。上記の図 5 から図 8 は結果をグラグ加工したものである。

これらの結果を見る限り、ディープラーニングによって学習させた人工知能は人間の認識力と同等またはそれ以上に達していると言えるだろう。

5. むすびにかえて：未来へ向けて

一般に公開されている人工知能ライブラリを用いて、機械学習の予測精度の検証とディープラーニングの認識能力の確認を行い、人工知能をどの程度簡単に使うことができるかを試行した。そこから、実際に一般の人が人工知能を活用するにあたって 2 つの課題があることが明らかとなった。

まず 1 つ目の課題として、機械学習に必要な分類方法の指定やモデルの定義を、プログラミング言語を用いて使用者が行わなければならないという点である。つまり人工知能を扱うためには、ある程度のプログラミングに関する知識が必要であり、経験のない人には難易度が高いと思われる。この点については、機械学習のみならず、ディープラーニングにおいても同様である。そこで、「C++」や「Java」のようなプログラミング言語と比較して、文法的に記述が簡単な Python を使うことを推奨したい。Python 言語を用いた処理の記述方法や、ライブラリの関数についての情報はある程度必要だが、多くの情報はインターネットから入手が可能であるため、初心者には扱いやすいと考えられる。

2 つ目の課題として、GPU のないパソコンで人工知能の学習処理を行うとその計算に多くの時間を要するという点である。試行を進める中で、ディープラーニングによる画像認識学習モデルの作成を試みたが、24 時間以上計算させても進捗度はほとんど上がらず、CPU の 100%稼働状態が続いたことによる熱暴走が懸念されたため途中で断念することにした。このことから、ディープラーニングの研究には GPU 環境が欠かせないことが判明した。

前述の 2 つの課題から、現段階において人工知能を使用する環境を構築するには、アイコンをクリックするような簡単な作業ではないということがわかる。便利な環境構築ツールはすでにいくつか提供されているが、それを利用しても機能が揃った理想的な環境を作成できるものではない。今回の試行で使用した TensorFlow の環境を作る場合がその例であり、人工知能のライブラリによっては、パソコン上でコマンドの入力を求められることになる。

「一般の人々が人工知能を扱うことは不可能か？」と聞かれれば、そうではないと答えたい。現段階ではやや難易度が高いと考えられるが、より簡単に環境構築ができるツールが開発され、様々な分野に応用できるライブラリが提

供されれば、人工知能の利用者は増えるであろう。前述で触れたプログラミング言語についても、人工知能向けのプログラミングを作る人工知能ライブラリが提供されることにより解決できる可能性は高いのではないだろうか。こちらが要望を伝えるだけでプログラミングを作成してくれることが実現すれば、より多くの人々が人工知能を手軽に活用できるようになる。近い将来、「ワンクリック人工知能」も夢ではない。

現在、人工知能は秘書機能アプリケーション「Siri」やお掃除ロボット「ルンバ」、自動車の自動運転技術等にすでに搭載されている。しかし、製品になってしまうとその能力は特化され限定的になってしまう。そのような中、ソフトバンク社が開発した感情ヒューマノイドロボット「Pepper」の登場は、人工知能が目に見える「かたち」として多面的に活用される一例ではないだろうか。

一方、人工知能の中でどういった処理が行われているのかが明確でないため、結果を導き出した理由が人間には理解ができないというのが現在のディープラーニングの特徴である。将棋や囲碁の世界でも、人工知能は人間を超える実力をすでに備えている。しかし何故ここまで勝てるのかは明らかではない。理由もわからず、人を超えた速度と正確さで判断できる領域に至っていることが、人工知能の怖い一面でもある。どこかで歯止めをかけなければ、社会の混乱を招きかねない。本稿では、研究者や企業だけでなく、個人として人工知能を活用するための必要な手順と課題を取り上げてきた。人工知能はこれからさらに社会に広く浸透するだろう。しかし、便利であっても手放しに活用するだけではなく、利用者個人が人工知能の隠れた危険性に留意してもらいたい。

謝辞

長年に渡りご指導をいただき、本稿を執筆する機会を与えてくださった根岸先生、編集にあたられた「経済学論究」編集委員会のみなさんおよび植田経済学部事務長に厚く御礼を申し上げるとともに、根岸紳先生の今後のご健康とご活躍をお祈りいたします。

参考・引用文献

Sebastian Raschka　福島真太郎 (監), 株式会社クイープ (訳) [2016] Python 機械学習プログラミング 達人データサイエンティストによる理論と実践（impress top gear）　インプレス

奥野卓司・岸則政・横井茂樹・原以起・奥野圭太朗［2017］人工知能と自動運転によるモビリティの変容と課題　AI 時代の「移動の社会学」に向かって　関西学院大学先端社会研究紀要　14 号 37-53.

斎藤康毅［2016］ゼロから作る Deep Learning ― Python で学ぶディープラーニングの理論と実装　オライリージャパン

マーティン・フォード［2015］ロボットの脅威 人の仕事が亡くなる日　日本経済新聞出版社

CNET［2017］Pepper が採用面接官に「SHaiN」が “AI 面接” のデモを披露
〈https://japan.cnet.com/article/35103469/〉（参照：2017-6-29）

総務省［2016］経済情報白書
〈http://www.soumu.go.jp/johotsusintokei/whitepaper/ja/h28/pdf/28honpen.pdf〉（参照：2017-5-20）

日本経済新聞［2017a］囲碁 AI、人間圧倒し「引退」　医療・エネに応用へ
〈http://www.nikkei.com/article/DGXLASFG27H7B_X20C17A5EA2000/〉（参照：2017-5-30）

日本経済新聞［2017b］最後の電王戦　将棋ソフトが名人に連勝
〈http://www.nikkei.com/article/DGXLASFG20H34_Q7A520C1000000/〉（参照：2017-5-30）

ロボット情報 WEB マガジン［2017］人工知能による運行サービス、自動運転サービスで衝突事故件数を 37%減〈https://robotstart.info/2017/07/20/sbwnauto.html〉（参照：2017-7-20）

参考 URL

ImageRecognition
〈https://www.tensorflow.org/versions/master/tutorials/image_recognition〉（最終アクセス日：2017-6-5）

NVIDIA GPU で加速化したコンピューティングとは？
〈http://www.nvidia.co.jp/object/what-is-gpu-computing-jp.html〉（最終アクセス日：2017-6-10）

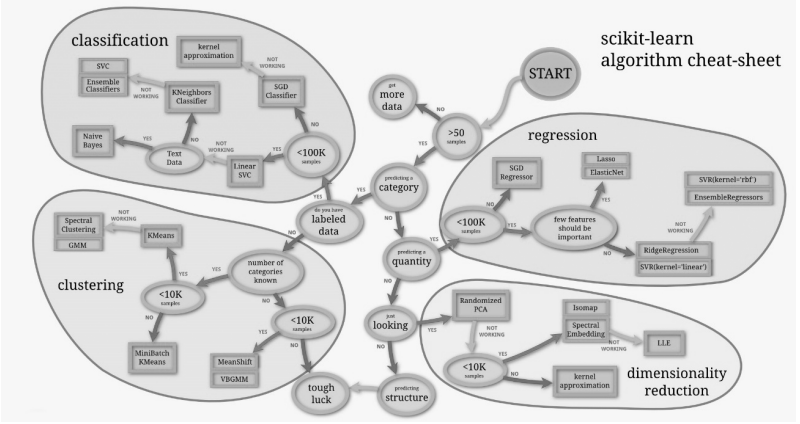
株価データサイト　〈http://k-db.com/〉（最終アクセス日：2017-7-14）

Scikit-learn　〈http://scikit-learn.org/stable/index.html〉（最終アクセス日：2017-6-5）

画像ファイル入手サイト　〈https://pixabay.com/ja/〉（最終アクセス日：2017-7-10）

付録

図 9　scikit-learn アルゴリズムチートシート



出典：http://scikit-learn.org/stable/tutorial/machine_learning_map/

図 10　株価予測試行のコマンド入力と結果出力のスクリーンショット

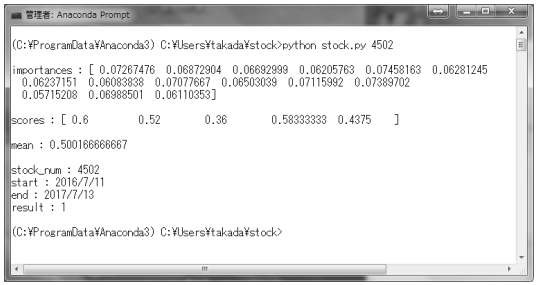


図 11　伸びた猫の写真の認識結果



basenji (score = 0.22352)
Pembroke, Pembroke Welsh corgi (score = 0.21720)
Ibizan hound, Ibizan Podenco (score = 0.06378)
dingo, warrigal, warragal, Canis dingo (score = 0.03461)
Saint Bernard, St Bernard (score = 0.02330)