

環境分野の深層学習研究を通じた人材育成

中根 英昭*

(受領日：2018年5月7日)

高知工科大学環境理工学群
〒782-8502 高知県香美市土佐山田町宮ノ口185

* E-mail: nakane.hideaki@kochi-tech.ac.jp

要約：人工知能（AI）のキーテクノロジーである深層学習（ディープラーニング）を用いて、高知工科大学環境理工学群環境解析研究室（中根研究室）では、環境分野のテーマに取り組んできた。その際、深層学習のプログラムを「実験装置」のように用いて、入力データに対する予測結果の応答を調べることで、現象の背後にあるプロセスや因果関係を探ることを、研究の一つの柱としている。本論文では、その一例として、ダムのない中小河川である安田川の水位の予測モデルの作成の際に、96時間（1時間分解能）の時系列データと12カ月（1か月分解能）の時系列データを入力データとした数値実験を行い、両者が必要であること、12カ月の時系列データが地下水の寄与を表現するために重要であることを示すことができた。このように、深層学習は、費用対効果の大きい予測手法であるのみならず、データに基づいてプロセスの理解や因果関係について論理的に考察する能力を養うための手段としても優れている。AIの大きな社会的インパクトに有効に対処するためにも、実際にAIの一種である深層学習による研究を行った経験は大いに役に立つと考えられる。

1. はじめに

高知工科大学環境理工学群中根研究室では、2016年度から、今日の人工知能（AI）の発展をもたらした深層学習（ディープラーニング）を用いた研究に取り組んでいる。2016年度には深層学習に用いるハードウェア・ソフトウェアシステムの構築を行い、2017年度には、修士課程2年生1名、4年生5名が深層学習を環境分野のテーマに応用した研究を修士論文、卒業論文にまとめて集立ったり。環境分野の限られたテーマについての、深層学習の中の限られた手法による研究であり、テーマについても限られた時間で結果が出そうな基礎的なものを選んで行ったものであったが、学生にとっても教員にとっても充実した時間であった。2018年度も6名が深層学習に取り組んでいる。

特に楽しいことは、深層学習のために作成したプログラムを「実験装置」として、入力データと出力（教師）データの工夫のために、教員と学生が討論することである。おそらく、学生同士でも教えあったり、議論したりしていると想像している。この過程で、「データから何を読み取るべきか」という科

学者・技術者として最も基本的なスキルを学んでいる。そして、「やはり深層学習で行っていることの意味を知らなければ気持ち悪い。」と言い出して、深層学習の基礎について勉強し始めるのである。「ブラックボックス」と言われることの多い深層学習が、実は「自然や人間の営みのプロセス」を探求するための、ある種の「実験装置」として教育的な側面を持っていることの一部をお伝えしたい。

2. 深層学習と数値シミュレーション

2.1 人間の認識と予測の枠組み

筆者と研究室の学生が現在取り組んでいる深層学習の位置付けを図1に示す。卒業研究では、ドローン空撮画像を用いた森林の樹種判別のようなテーマにも取り組んでいるが、ここでは主に気象現象や河川水位等に関するテーマへの取り組みを取り上げる。具体的な例について述べる前に、深層学習という技術が、人間の認識においてどう位置づけられるか、についての筆者の見解を述べたい。

図2は、人間が現象を観察して、あるいは行動の結果として生じた現象から結果を推定し、その認識

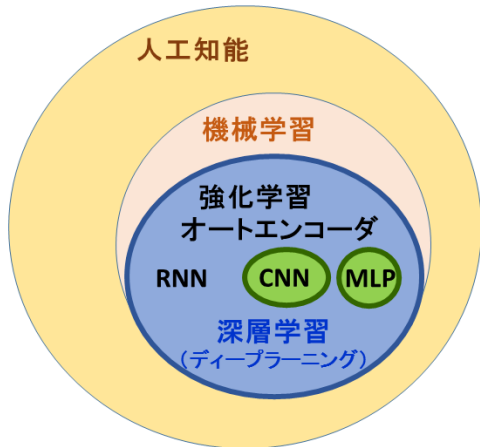


図1. 中根研究室において取り組んでいる深層学習の位置。緑色で囲んだ、「畳み込みニューラルネットワーク (CNN)」と「多層パーセプトロン (MLP)」に取り組んでいる。

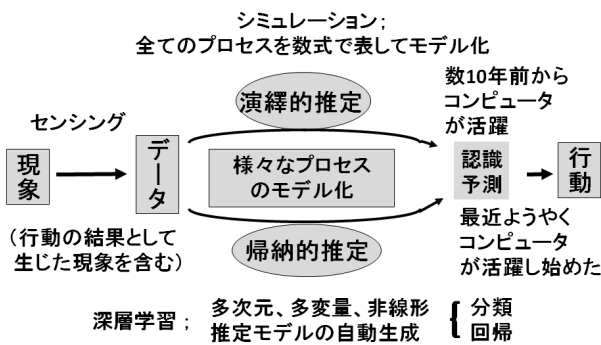


図2. 人間の認識・予測・行動における演繹的・帰納的推定、シミュレーション・深層学習とコンピュータの関係

に基づいて行動する過程を示したものである。人間は、生きてきた時代の文化、哲学、宗教、技術水準等によって影響を受けながら、古くから演繹と帰納の二つの推定手法を用いて現象の背後にあるプロセスを理解し、結果を予測して行動してきたに違いない。そして、行動の結果生じた現象の変化を知覚し、プロセスへの理解と予測精度を高めてきたのであろう。人間の、この一種の本能とも言える営みについて、松尾豊氏は著書「人工知能は人間を超えるか」において簡潔に述べている²⁾。

人間は、(時には必要以上に) 原因と結果という因果関係でものごとを理解しようとするが、それはつまり、動物として行動の計画に活かしたいからだろう。

「(時には必要以上に)」は含蓄に富んだ言葉である。

2.2 コンピュータによって強化された演繹的予測 —数値シミュレーション—と深層学習

因果関係を論理によって理解する演繹法は、数学的表現を獲得し、さらに計算機の発達と共に定量的な予測の精度を高めてきた。数値シミュレーションにおいては、自然や社会の諸過程を全て数式に表し離散化することができる限り、コンピュータを用いた予測が可能である。複雑系に特有のカオスの振る舞いによる予測の誤差は拡大するが、観測データを取り入れる「同化」によって、10日程度までの天気予報は社会インフラと言ってもよい予測精度を獲得している。このように、演繹法の一つである数値シミュレーションは、この数10年の間、コンピュータの発達の恩恵を享受してきた。宇宙開発における軌道予測や流体力学的シミュレーション等も然りである。

帰納的な推定・予測については、確かに統計的解析や可視化等がコンピュータの発達の恩恵を受けてきたことは疑いないが、2010年代に入るまではシミュレーション程の成功を取めてきたとは言い難かった。しかし、この数年間の深層学習の発達により、帰納的推定・予測についてもコンピュータの発達の恩恵を全面的に享受することができるようになった。これにより、人間は再び、「演繹的推定と帰納的推定の2足歩行」をバランスよく、昔とは比較できないほど力強く行うことができるようになった、と筆者は考えている。

実は、シミュレーションにおいても、すべてのプロセスを数式で表すことを厳密に行うことは困難であり、近似式のパラメータを実測に合うように決めている場合が多い。このように、部分的に帰納的手法を用いている部分に対して深層学習を用いて精度を高める、ハイブリッド型は効果的であろう。しかしながら、シミュレーションのためのコンピュータ、人的資源、時間的資源と比較すると、深層学習による推定・予測手法は、大きな費用対効果が得られる可能性があり、様々な分野において大きなポテンシャルを持っていると考えている。

3. 深層学習による河川のモデル化を通じて論理的思考を学ぶ

ビジネスの観点から論じられることの多いAIのキーテクノロジーである深層学習が、数値シミュレーションと並ぶコンピュータで支援された人間の認識・予測能力の発展であることを前章で見えてきた。ブラックボックスと言われることの多い深層学習が、実は、「現象の背景にあるプロセスを定量的

にモデル化し、数値実験を行うことによって、因果関係を探る」ことのできる教育的な「実験装置」でもあることを、河川水位の推定を例として示す。

3.1 数値シミュレーションによる河川水量の推定

まず、河川流量の数値シミュレーションと、考慮されているプロセスの典型的な例を示す。図3は、気象庁の流域雨量指数（流量の平方根）の計算に用いられているシミュレーションの模式図である。

流域雨量指数の計算は、「河川流域を1km四方の格子（メッシュ）に分けて、降った雨水が、地表面や地中を通して時間をかけて河川に流れ出し、さらに河川に沿って流れ下る量を、タンクモデルや運動方程式を用いて数値化した」³⁾ものである。「流下」の部分は流体力学的な運動方程式であるが、「流出」の部分については、「タンクモデル」を用いて近似されている。すなわち、「都市域では、表面流出が主体の5段タンクモデルを用い、非都市域では、直列3段タンクモデル（地質に応じた5種類の流出特性の異なるモデル）」³⁾を用いている。タンクモデルにかかわるパラメータは、現実の河川の降水量、流量等に合うように調整される。このようにして、河川水位は河川水量と河川形状から計算することができる。

3.2 深層学習による「数値実験装置」の作成

深層学習では、河川水位や流量を比較的単純な道具立てによって計算することができる。具体的には、図4に示すような多層パーセプトロン（MLP）である。この構造は、深層学習に用いるニューラルネットワークの中でも単純なものであり、「入力層」、「中間層」、「中間層」、「出力層」の4層から構成される。中間層（隠れ層）数やノードの数を増減させる自由度がある。

MLPを用いて、流域圏降水量から河川水位を推定するモデルを自動作成できる。我々はグラフィックスプロセッシングユニット（GPU）による並列計算によって推定モデルの作成を行ったが¹⁾、通常のPCのCPUでも実行可能と思われる。河川水位推定モデルの作成に用いたアプリケーション（フレームワーク）は、Tensorflowをバックエンドに用いたKeras⁴⁾である。日本で開発されたChainerの他、Caffe等の様々なフレームワークが利用可能であるが、開発の経緯からKerasを用いている¹⁾。Kerasによって、深層学習の実装のためのプログラミングの負荷が軽減され、作成すべきモデルの設計と数値実験に集中できることは有難い。図4のMLPのモデル作成と




図3. 気象庁の流域雨量指数計算において考量されているプロセスと計算式³⁾




図4. 河川水位の推定に用いた多層パーセプトロン

コンパイルは下記；

```
model = Sequential()
model.add(Dense(256, input_dim = channels))
model.add(Activation('relu'))
model.add(Dropout(0.25))
model.add(Dense(512, activation = 'relu'))
model.add(Dropout(0.25))
model.add(Dense(1))
model.compile(loss = 'mean_squared_error',
              optimizer = 'adam')
```

のPythonプログラムの実行によって可能である（詳細は省略している）。深層学習モデル設計のためのプログラミングが容易であるため、データ入出力や可視化のプログラミングに集中できる。このようにして作成したプログラムを「実験装置」として、入力データを変化させ、観測データをより良く再現できる推定モデルの作成を行った。

3.3 ダムのない高知県の中小河川、安田川の水位 —特に、「緑のダム」の効果について

安田川は、流程約 30 km の河川全体を通してダムが存在しない二級河川であり、アユやアマゴ、天然の大ウナギが生息する清流である。流域の自治体は、高知県安田町、馬路村である。下流に近い東島観測所で水位を観測している。東島観測所の水位と気象庁の「解析雨量」⁵⁾の1時間値を基に、深層学習によるプログラムを作成した。

この観測所の水位を推定するモデルを深層学習によって作成するためには、まず、水位を決める要因を挙げる必要がある。例えば、以下のように考察する。

- 流域圏の降雨量：雨が降る場所によって降雨量が異なり、水位への影響も異なるが、第一近似として流域圏平均雨量を使用する。
- 潮の干満の影響：影響があれば入力データに含める必要がある。スペクトル解析で半日周期にピークが現れなかったことから、影響はないと判断した。
- どのぐらいの期間の雨量の時系列を入力データとして用いるか：降雨量が急に増えた時の水位の上昇は1~2時間遅れであるが、降雨終了後、水位はゆるやかに下がる。入力データに含める雨量の時系列の期間について感度解析（数値実験）を行った上で、長めに4日（96時間）の雨量の時系列を入力にすることにした。

以上のようにして、教師データである水位観測値に対応する過去の96時間（分解能：1時間）の降雨の時系列を入力として水位推定モデルを作成した。プログラム中の“channels”を96としたことになる。このことはまた、図4のMLPの入力層のチャンネル数を96にしたことになる。入力データと教師データを80%の「訓練データ」と20%の「テストデータ」にランダムに分割し、訓練データを用いて学習を行い、水位推定モデルを作成した。テストデータを用いて、モデル推定水位と観測値の比較を行った結果を図5の散布図に示した。水位が高い場合の一致は良いが、水位が低い程モデル推定値と観測値の一致が良くない。

そこで、図3を参考に、低水位時の河川水は何によって維持されているかを踏まえ、モデルの改良を行った。

- 「流出」過程の入力データへの反映：積雪の影響も降雨量として扱い、数カ月の時系列データを含めればよい。1か月平均雨量の12か月時系列を入力データに追加する。




図5. 安田川流域圏平均雨量96時間時系列データを入力データに用いた場合の東島観測水位の散布図⁶⁾




図6. 入力データとして降水量の96時間時系列に1か月平均値の12カ月の時系列を加えた場合の東島観測水位の散布図。他の詳細は図5に同じ⁶⁾。

- 過去96時間の時系列と過去12カ月の時系列の両者を入力データとする。入力層のチャンネル数を108とする。
- 96時間時系列と12か月時系列には重複があるが、深層学習による「重みの自動最適化」によって解決されることを期待する。

上記によって水位が低い期間の水位の推定が大幅に改善されるという仮説を、数値実験によって確認するために図5と同様の散布図を作成した（図6）。負の水位を含む低水位から、豪雨によってもたらされる高水位まで、データが原点を通る傾きが1の直線の周りにコンパクトに分布している。

さらに、典型的なケースについて観測値とモデル推定値の一致について確認するために、高水位および低水位の期間について観測値とモデル推定値の




図7. 入力データとして降水量の96時間時系列に1カ月平均値の12カ月時系列を加えた場合の東島観測水位 (cm) の時系列の比較 (緑: 観測値、青: モデル推定値)。2007年7月、台風4号接近時⁶⁾。




図8. 入力データとして降水量の96時間時系列に1カ月平均値の12カ月の時系列を加えた場合の低水位時 (2012年5月~6月) の東島観測所の水位の時系列の比較 (緑: 観測値、青: モデル推定値)⁶⁾。

時系列データの比較を行い、図7、図8に示した。時系列データにおいても、モデル推定値は観測値と良い一致を示している。入力データに12カ月の降水量時系列を含めない場合の、図8に対応する図を図9に示す。低水位時には、過去1年間の時系列データを入力データに含めることが不可欠であることを確認することができる。このことは、図3の数値シミュレーションの説明において、「タンクモデル」で表されている「流出」過程、いわゆる「緑のダム」の効果が、深層学習においては、入力データに過去1年間の降雨量の時系列を追加することによって表現できることを示している。なお、何か月前の降雨の寄与が大きいかを調べるために、1カ月




図9. 96時間時系列データのみを入力データに用いた場合の東島観測水位 (cm) の時系列の比較。(緑: 観測値、青: モデル推定値)。低水位時 (2012年5月~6月)⁶⁾。

平均値の時系列データの長さを変えて図5、6のような散布図を作成したところ、3カ月と6カ月で大きな違いが見られた。安田川の場合、3~6カ月の間の降雨が「緑のダム」にとって重要なのである。

しかしながら、解明すべき課題が山積していることも明らかである。まだ、水位に10cm程の違いがある。流域圏の降雨分布を反映した入力データを与える必要があると思われる。また、モデル推定値に見られる不必要な振動は、モデルのパラメータの調整によって除去すべきであろう。ただ、モデルが単純であるが故に、改善の余地は大きいと考えている。

3.4 人間の営み—ダムからの放流量のモデル化に関する考察

ダムのない安田川の水位を例に、「緑のダム」の効果、深層学習を用いたモデルの中で表現する試みについて述べてきた。では、人工のダムがある場合についてどう考えるべきであろうか? 以下のような議論を行うことになると思われる。

- ダムのすぐ下流の水位は、ダムの放流量で決まると考えて良い。
- 水位予測を行うためには、ダムの放流量が何によって決定されるか、に関するモデル化が必要である。これは、「緑のダム」のような自然の営みに加え、「人間の営み」をモデル化することになる。
- ダムの放流量はダムの目的に依存するが、ダムの水位 (貯水量)、過去の降雨および予想される近未来の降雨、電力需要、水需要等を考慮して決定しているはずである。

- 下流における支流からの流入量や都市からの流入、潮の干満をも考慮したダムへのオペレーションが行われている場合には、これらも入力データに含めることが必要であろう。
- また、ダムの貯水量変化に等しいと考えられる、「ダムへの流入量ーダムからの総放流量」、すなわち、正味流入量を上流の「緑のダム」の効果を含めてモデル化することも、ダムへのオペレーションを含めた下流の水位予測の精度を高めると考えられる。

ダムを含めた河川水位のモデル化を行う際には、上に挙げた様々な要因の相対的な重要性を明らかにするために、入力データに加える、除く等による数値実験を行うことが有効と考えられる。その際、研究の目的に応じて、考察の対象とする時間スケールに留意する必要がある。

3.5 先行研究を踏まえた考察

洪水予測への機械学習の応用については、精力的に取り組まれてきており、その概要は、河川情報センターが開催した平成29年度河川情報シンポジウム講演集に掲載されている「AIによる洪水予測と水位データの異常検知」⁷⁾に詳しい。この総説では、主に2000年代に行われた3層の「浅層順伝播型ニューラルネットワーク」による洪水予測研究について、「ピーク生起時刻の予測と実績の差、ピーク水位の予測と実績の差の精度が十分ではなく、概念的貯留関数法、概念的タンクモデル、物理的斜面流出モデルと組み合わせる方法、カルマンフィルタ等の同化技術を適用し予測精度の向上を図る等している。」と述べている。そして、「深層順伝播型ニューラルネットワーク」、「動的（時間遅延）ニューラルネットワーク」、「WaveNet」、「Long Short Term Memory: LSTM」、「多層マルチモーダル LSTM」について紹介しつつ、同センター自身が大規模な取り組みを行っていることを紹介するとともに、河川分野でAIが有効であることを強調している。また、日本工営の一言正之氏は、深層学習（4層のニューラルネットワーク）の洪水予測への応用に系統的に取り組んでおり⁸⁾、図3に示したような分布型モデルとの「ハイブリッド型」のモデルを提案している⁹⁾。千代田エンジニアリングの竹村仁志氏は、2000年代から3層ニューラルネットワークによる洪水予測に取り組んできたが¹⁰⁾、さらに、流出モデルとニューラルネットワークを組み合わせ、ダムを含めた相模川の洪水予測システムを構築し、その検証を行っている¹¹⁾。

これらの先行研究では、洪水予測が目的であることから、洪水時のデータのみから学習モデルを作成していることが多く、筆者らのような、洪水時から渇水時までを切れ目なく深層学習によってモデル化するという発想ではないように思われる。渇水時の予測は、河川生態系や灌漑の観点から重要である。洪水の予報のための降雨予測は容易ではないが、降雨のない状況が続く場合の水位予測が行えることは、このモデルの大きな長所であると考えられる。

また、先行研究の多くは、深層学習による過去のデータを上回る水位への外挿は困難であるという暗黙の前提に基づいて行われている感がある。筆者らは、鏡川宗安寺観測所の水位について、「想定外」ではないが、過去5年以上の最高水位を上回る水位についても良い精度で推定できるモデルを作成している¹⁾。

単純な4層MLPによって上記の二点のような先行研究にない特長をもった推定モデルを作成できている要因については、入力データについて、教育的見地も手伝って、「大胆に変えてみる」ことに躊躇しなかったことや、外挿にも挑戦してプログラミングにおいて試行錯誤を重ねたことによると考えている。また、順調に精度の高い推定モデルが得られた理由として、Kerasによって構築した深層学習モデルにおいて、「ドロップアウト」、「活性化関数: ReLU」、「オプティマイザー: Adam, Nadam」等の最新のオプションを選択し、関連するパラメータについても検討し、実際の応用に即した選択になっていたと推察している。MLPは極めて費用対効果の高いモデル作成手法であるが、今後、先行研究で行われているような、水位やダムへの流入量等の河川諸量の数時間予報が可能であることを実際に確認する必要がある。その際、気象庁の解析雨量の予報値を使用することや、流域圏平均雨量ではなく、降雨量の分布を入力にした深層学習が必要になると考えている。その場合には、CNNを用いた回帰を用いることも選択肢の一つである。

4. 環境とAIについて学ぶ意味

4.1 環境に関する多様なテーマによって育つ勉強意欲と「AI相場観」

一つの例に過ぎないが、深層学習の研究を通じて、学生がデータについてより深く考えるきっかけを作りつつ研究を進めていることをご紹介させて頂いた。また、深層学習のプログラムが「仮説を（数値）実験で確かめる」というサイクルを回して学ぶことに適していることについても触れた。中根研究

室の2017年度の修士論文、卒業研究のテーマの内容は、以下の通りであった¹⁾。

(1) 畳み込みニューラルネットワーク (CNN) を用いた研究

- ひまわり7号赤外雲画像による高知の降水の有無
- ひまわり7号可視画像による全天日射量推定
- 転移学習による3種のユリの花の画像の判別
- 転移学習による森林空撮画像を用いた樹種判別

(2) 多層パーセプトロン (MLP) を用いた研究

- 早明浦ダムの流入量推定
- 安田川の水位推定
- 鏡川の水位推定

それぞれのテーマで、学生と教員の討論の中から小さな発見が生まれ、それが研究の動機づけになっている。

一度 CNN や MLP の基本的なプログラム作成すれば、様々なテーマのためのプログラムを作成することが容易であり、それぞれのテーマにおいては、データの意味、対象としているプロセスの意味、目的としているところについて考えつつ、数値実験を行うことができる。このような一種の「アクティブラーニング」を通して、修士課程に進んだ学生や2018年度の4年次の学生達は、深層学習の基礎について再度学習する意欲が湧いてきているようである。

ここで、環境をテーマにして深層学習について学ぶ意味、意義について論じたい。環境プログラム科目等を通して、環境に関するテーマにすでに親しみを持っている学生であること²⁾も考慮してテーマを選択していることも一因であるが、環境をテーマにした大きな理由の一つは、特定のビジネスと強く結びついたテーマでない方が、卒業後に様々な分野の企業、公的機関等の課題に柔軟に取り組みやすいと考えたためである。インターネット上のいわゆるビッグデータだけではなく、各企業が有している「自前のビッグデータ」の解析においてこそ、深層学習が役に立つのではないかと考えている。特に、今後定年を迎える熟練技術者の経験知を「教師データ」として、深層学習によるモデル化を行って継承する課題は、中小企業を含めて多くの企業や公的機関のニーズであると考えられる。このような課題に直面した時に、業務の目的と存在するデータから、適切で費用対効果の高い深層学習の手法について検討することのできるセンスを磨いた人材こそ、大きな貢献が可能になるであろう。さらに、商社やコンサルタント等においては、様々な顧客のニーズに

AI が有効か否かの相場観が重要である。環境に関する様々なテーマに対して様々な手法の深層学習によって取り組む学生が研究室にいることは、AI に関する相場観を養う最適の環境と考えている。

4.2 人間と社会に対する AI のインパクトへの対応

環境をテーマにするもう一つの理由は、AI が、「人間の幸せのために、地球生態系が持続可能であるという条件の下で、社会と経済の持続可能な発展を目指す」という現世代と次世代にとっての大きな課題¹²⁾に対して、ポジティブあるいはネガティブな、あるいは両方の大きなインパクトを与えるに違いないからである。

現時点では、AI は世界的に格差を拡大し、世界を不安定化しているように見える。例えば、新井紀子氏は、次のように警告している¹³⁾。

…それが AI によって起こるディスラプティブな（破壊的な）社会変化です。この時代を乗り切れない企業は、破たんしたり吸収されたりする前に、人間を過酷に働かせたり、品質管理を疎かにしたりすることで AI に対抗しようとしがちになります。当然、職場はブラック化しやすくなり、不祥事が起きやすくなるはずです。

余りにもリアリスティックな警告である。自らが「AI にできない仕事ができる人間になる」と共に、AI によって淘汰される企業か、AI によって伸びる企業か、AI の波をうまく乗り切る企業かを見分けるためにも「AI 相場観」を持つ必要がある。言い換えると、AI の本質や、人間や社会への影響について自ら考えることが必要なのである。その際、AI のキーテクノロジーである深層学習を用いた研究を行った経験は、AI の可能性と限界を知るために有効であろう。「持続可能な社会」や「環境とイノベーション」等について系統的に学んだ学生にとっては、さらに有効であろう¹²⁾。

ポジティブなインパクトは、ポテンシャルとしては大きい。産業革命による生産性の向上が、人間の力仕事の多くを機械が肩代わりすることによって実現したのと同様に、AI による生産性向上は、人間の単純な知能労働を AI が肩代わりすることによって実現するからである。AI による生産性向上が人間の幸福につながるか否かは、やはり人間の選択にかかっているはずである。新井紀子氏が「ひとすじの光明」として挙げる、デジタルと AI を味方につけた「世の中の困ったこと」を解決する起業と共に、筆者は「アジェンダ 2030 (SDGs)」¹⁴⁾にも「ひとす

じの光明」を見出している。「このようなことがまだ解決されていない」と同時に、「このようなこと」を諦めずに2030年までに解決することに、国連総会において全会一致で合意したのである。グローバル化の「ひとすじの光明」でもある。そして、海外投資や貿易によって年間約20兆円もの経常収支の黒字を得ている日本にとって、「消してはならない光明」と、筆者は考えている。

5. おわりに

2019年3月に高知工科大学の定年を迎えることから、招待論文を書く機会を頂いた。そこで、「環境プログラム」と「深層学習による環境応用研究の立ち上げ」に関する2報の報告^{1),12)}と共に、深層学習を用いた研究を実際に行うことの教育的効果について書きたいと考えた。研究室の学生にとって、Pythonによるプログラミングを勉強し、深層学習の基礎について数学も含めて勉強してから研究に取り組むのでは、研究が始まる前に1年が過ぎるであろうこと、1年経つ前に挫折するであろうことは容易に想像できた。そこで、「まず深層学習を用いて研究テーマに取り組んで、必要なことをその都度勉強する」を学生に提案し、実行して貰った。概ね成功したと考えている。

「AIとどう付き合えば良いか？」を考えることは、個人にとっても社会にとっても避けられない課題である。本論文が、この課題に取り組む方々に少しでもご参考になれば幸いである。

謝辞

本論文を書くきっかけを与えて下さった、中根研究室大学院生、学生の皆さん、小島慶之君、若槻祐貴君、明田啓暉君、林良真君、増本雄大君、松浦栄理さんに感謝致します。特に小島君には、実例として修士論文の内容を引用させて頂きました。ありがとうございます。深層学習に取り組むきっかけを作って下さった大阪大学三宅淳特任教授に、お礼申し上げます。河川に関してご教示頂いた高知工科大学那須清吾教授、吉村耕平助教、データサイエンス、気象、シミュレーションに関してディスカッションして下さい、高知工科大学環境理工学群、古沢浩教授、柴田清孝教授、全卓樹教授、中前久美氏に感謝いたします。また、河川データを提供して下さい、高知県土木部河川課のご協力に感謝致します。最後に、本招待論文を執筆する機会を与えて下さった高知工科大学紀要委員会に深くお礼申し上げます。

ます。

文献

- 1) 中根英昭, 若槻祐貴, “環境分野への深層学習応用研究の立ち上げについて”, 高知工科大学紀要, Vol. 15, pp. 111–120, 2018.
- 2) 松尾豊, “人工知能は人間を超えるか ディープラーニングの先にあるもの”, KADOKAWA, p. 184, 2015.
- 3) 気象庁ホームページ, URL = <http://www.jma.go.jp/jma/kishou/know/bosai/ryuikishisu.html>.
- 4) Keras Documentation ホームページ, URL = <https://keras.io/ja/>.
- 5) 気象庁ホームページ, URL = <http://www.jma.go.jp/jma/kishou/know/kurashi/kaiseiki.html>.
- 6) 小島慶之, “ディープラーニングを用いた安田川の水位推定モデル”, 高知工科大学大学院工学研究科基盤工学専攻物質生命システム工学コース平成29年度修士論文, 2018.
- 7) 岡田 治, 柿澤 一弘, 田所 正, 中安 正晃, “AIによる洪水予測と水位データの異常検知”, 平成29年度河川情報シンポジウム講演集, pp. 3.1–3.16, 2017.
- 8) 一言正之, 櫻庭雅明, 清雄一, “深層学習を用いた河川水位予測手法の開発”, 土木学会論文集 B1 (水工学), Vol. 72, No. 4, pp. I.187–I.192, 2016.
- 9) 一言正之, 櫻庭雅明, “深層ニューラルネットワークと分布型モデルを組み合わせたハイブリッド河川水位予測手法”, 土木学会論文集 B1 (水工学), Vol. 73, No. 1, pp. 22–33, 2017.
- 10) 春原常男, 内海博, 井上勝矢, 眞間修一, 吉田武司, 竹村仁志, “ニューラルネットワークモデルによるダム諸量予測と相模川洪水予測システムの検討”, 河川技術論文集, Vol. 12, pp. 229–234, 2006.
- 11) 竹村仁志, 眞間修一, 吉田武司, 石上尚, “中流域に洪水調節ダムを有する河川における洪水予測システムの精度検証”, 河川技術論文集, Vol. 19, pp. 247–252, 2013.
- 12) 中根英昭, 古沢浩, “「環境プログラム」の新たな展開”, 高知工科大学紀要, Vol. 15, pp. 105–110, 2018.
- 13) 新井紀子, “AI vs. 教科書が読めない子どもたち”, 東洋経済新報社, p. 270, 2018.

- 14) SUSTAINABLE DEVELOPMENT KNOWLEDGE PLATFORM ホームページ, URL = <https://sustainabledevelopment.un.org/post2015/transformingourworld>.
- 15) 財務省ホームページ, “平成 29 年度中国際収支状況(速報)の概要”, URL = https://www.mof.go.jp/international_policy/reference/balance_of_payments/preliminary/pg201803.htm.

Human Resource Development through Deep Learning Research in the Environmental Field

Hideaki Nakane*

(Received: May 7th, 2018)

School of Environmental Science and Technology, Kochi University of Technology
185 Miyanokuchi, Tosayamada, Kami City, Kochi 782–8502, JAPAN

* E-mail: nakane.hideaki@kochi-tech.ac.jp

Abstract: Using deep learning, the key technology of artificial intelligence (AI), the Nakane Laboratory of the Kochi University of Technology has been carrying out studies in the environmental field. In order to examine the processes and causal relationships behind the phenomena, “numerical experiments” were applied by examining the responses of the predicted results to the input data. In this paper, as an example, the water levels of the Yasuda River, which is a medium-sized river without a dam in Kochi Prefecture, were predicted using deep learning. 96 hours (1-hour resolution) and/or 12 months (1-month resolution) time series data were selected as the input data of the Multi-Layer-Perceptron (MLP). The results of the numerical experiments showed that the time series data of 12 months are important for representing the contribution of groundwater. In this way, deep learning is not only a cost-effective prediction method, but also a means to nurture student ability to logically understand the processes and to find causal relations based on the data. In order to effectively deal with the large social impacts of AI, research experience using deep learning would be beneficial.