

# 環境分野への深層学習応用研究の立ち上げについて

中根 英昭<sup>1\*</sup> 若槻 祐貴<sup>2</sup>

(受領日：2018年5月7日)

<sup>1</sup> 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

<sup>2</sup> 高知工科大学大学院工学研究科環境数理コース  
〒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：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、2016年度後半に深層学習のための計算機環境を整備し、2017年度当初から、具体的な環境分野のテーマへの応用に取り組み、2017年度中に所期の成果を上げることができた。深層学習による回帰および分類（判別）のための推定モデル作成の対象は以下の通りである。回帰の対象は、早明浦ダムへの流入量、安田川の水位、鏡川の水位、高知の全天日射量である。分類（判別）の対象は、高知における降雨現象の有無、3種のユリ科の花の種類、森林の樹種である。対象は多岐にわたるが、多層パーセプトロン（MLP）と畳み込みニューラルネットワーク（CNN）の2種類の深層学習の手法によって推定モデルの作成を行うことができた。回帰においては、増水期から渇水期に至る全期間の水位やダムへの流入量を、外挿も含めて良好にモデル化できることを示した。ドローン空撮した森林写真から切り出した画像を用いた森林樹種分類に際しては、転移学習によって人間と同等あるいはそれ以上の識別が可能であることを示すことができた。

## 1. はじめに

深層学習（ディープラーニング）は、近年の人工知能の急速な発展にとって鍵となる技術である<sup>1)</sup>。パーソナルコンピュータ（PC）の高速化、並列計算を行うことが可能なGPU（Graphics Processing Unit）の低価格化、深層学習のためのソフトウェアライブラリー（フレームワーク）がオープンソースとして公開されていることから、極端な言い方をすれば、「だれでも深層学習を活用できる」環境が出現している。

高知工科大学環境理工学群中根研究室では、2016年度から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年度から具体的なデータを解析するプログラムの作成を開始した。2017年度末には、深層学習のいくつかの手法を環境分野のテーマに応用した結果が得られ、有効な研究手段であると考えに至ったため、2016～2017年度にかけて実施したシステムの立ち上げの

経緯と研究例について報告する。

## 2. 大阪大学基礎工学部における先行研究

環境理工学群では、学群コロキウム「理工学のフロンティア」<sup>2)</sup>を1年に10～20回開催しており、2016年4月19日に大阪大学基礎工学部三宅淳教授（2017年度より大阪大学国際医工情報センター特任教授）による「ディープラーニングが解く世界」と題する講演が行われた。講演では、

- (a) バイオ応用として、DNAレベルの進化、タンパク質の突然変異や細胞の分化誘導、細胞内の遺伝子や化学反応の連鎖（例えばガン化メカニズム）
- (b) 知能と運動の研究として、ロボットと人間の認識共有、テロリストの検知・人間の行動解析などについての三宅研究室において実施されている研究<sup>3,4)</sup>、の紹介と共に、将来の研究の方向性や可能性について述べられた。講演後の研究打合わ

せでは、気象現象推定モデルの開発についての共同研究の可能性について検討した。三宅研究室では、当時2名の卒業研究生がこのテーマに取り組んでおり、その成果の一部が、後に日本気象学会 2016 年秋季大会で発表された<sup>5)</sup>。

2017 年 3 月に三宅教授が大阪大学基礎工学部を退職される際に、深層学習による気象現象の推定に関する卒業研究の情報、使用したデータ等を共有して共同研究を行うことになった。

### 3. 環境理工学群中根研究室における開発 (2016 年度後半～2017 年度前半)

#### 3.1 深層学習に必要な計算機環境の整備

三宅教授の研究室では、GPU を備えた PC、OS として Linux、深層学習のフレームワークとしては独自に開発した「Σ」、プログラミングは C++ を用いていた。筆者らを含む中根研究室のメンバーにはハードルが高く、そのまま模倣して使わせて頂くことは困難と考えた。ただ、GPU の使用は不可欠と考えた。また、フレームワークとして、Caffe、Chainer、Tensorflow、H<sub>2</sub>O などがある中で、「どれも試してみるのが良い」というアドバイスや、「Tensorflow が良い」等のアドバイスを、様々な方から頂いていたことから、とりあえず Tensorflow による環境構築を目指した。2016 年 10 月には、中根研究室修士課程 1 年生の小島慶之君が、名古屋大学太陽地球環境研究所の長濱智生准教授のご協力の下、GPU を装着しない Linux-PC に Tensorflow をインストールして計算させることに成功した。2016 年 11 月中頃には Windows/Linux の両方の OS が搭載された PC に GPU (GeForce GTX1070) を搭載した。しかし、GPU 版の Tensorflow のインストールは困難であった。

2016 年 11 月 29 日に Google から Windows 用の Tensorflow が公開された。また、11 月 30 日には、オーム社より「実装ディープラーニング」<sup>6)</sup> が出版された。この本の中の GPU を使うための環境設定に関する詳細な記述は、Linux への実装ではあるが、大いに役立った。さらに、Keras というインターフェースからバックエンドの Tensorflow や Theano を動作させると機械学習のプログラミングが容易になるとの記述もあり、参考になった。また、インターネットのエンジニア同士の情報交換サイト「Qiita」にも「Tensorflow が正式に Windows サポートして GPU が使えたので試してみた」という記事が 2016 年 12 月中頃にアップロードされた<sup>7)</sup> ため、Window-PC に Tensorflow のインストールを試みたところ、特段の困難もなくインストールすることができた。数字の

表 1. 深層学習に用いた計算機環境例

CPU	Core i7-7700
GPU	GeForce GTX1070 or GTX1080Ti
OS	Windows 10
フレームワーク	Keras / TensorFlow
プログラミング言語	Python 3.6 (Anaconda 4.4.0)

0～9 を判別する手書き文字認識「MNIST」のサンプルプログラムを実行したところ、CPU のみで実行した場合に約 1 時間かかっていたプログラムが、GPU を用いた場合には約 1 分で完了することを確認できた。このとき、「深層学習の大衆化」の時代が到来したことを感じた。

中根研究室では環境データの解析に R 言語を用いていたことから、機械学習のコミュニティで良く使用されている Python には不慣れであった。それに加えて Tensorflow の文法の学習をするのは大きな負担であったことから、Tensorflow のためのインターフェースである Keras<sup>8)</sup> を使い、Python によって深層学習用のプログラムを作成することにした。Keras にとって Tensorflow はバックエンドとして用いることのできる機械学習ライブラリの一つであり、他に、Theano、CNTK をバックエンドとして用いることができる<sup>8)</sup>。実際のプログラミングの際には Tensorflow を意識することは現時点ではない。Python については、ライブラリ間のバージョン管理の容易な Anaconda によってインストールすることにした。プログラム作成には、Anaconda のライブラリに含まれている Spyder を用いた。R 言語によるプログラム開発環境として用いていた Rstudio と類似した環境であるためである。表 1 に利用している計算機環境をまとめた。以前から環境データ解析用に用いていた Windows PC に GPU が搭載されたグラフィックボードを追加した場合には、追加的な費用は数万円 (GTX1070 の場合)、10 数万円 (GTX1080Ti の場合) である。

我々の研究室では Keras / Tensorflow を Windows 上で実行しているが、Keras の中心的開発者である Francois Chollet は自著“Deep Learning with Python”の“Software / hardware requirement”<sup>9)</sup> において“‘You’ll need access to a UNIX machine; it’s possible to use Windows too, but I don’t recommend it’”とはっきりと述べていることに留意する必要がある。実際、アップデートの際のバージョンの不整合に対するサポー

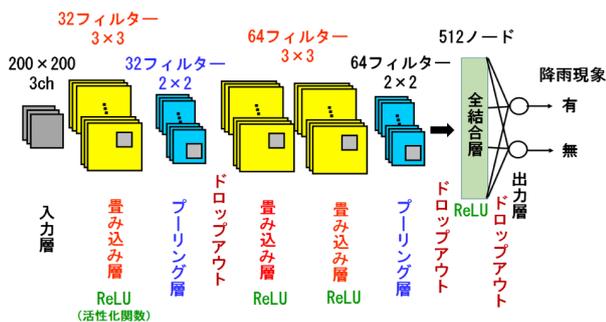


図1. 使用したCNNの構造。畳み込みのストライド幅は1、パディング有り。

トにおいてLinuxが優先されていると感ずることがある。

### 3.2 Keras/Tensorflowによる大阪大学の研究例の再現・改良

深層学習のプログラム開発環境がほぼ整った2017年3月に、中根研究室の3年生5名全員に、「卒業研究のテーマは深層学習の環境分野への応用であることを」を確認した。修士課程1年生の1名と併せて6名の研究テーマのために、短期間で成功例を示す必要があった。本報告の著者の一人である若槻が大学院に進学予定である他は、就職活動が始まっていたことから、先ず、中根と若槻の二人で大阪大学の研究例の再現に取り組んだ。再現する研究例を、大阪大学基礎工学部三宅研究室岩井尚晴氏の卒業論文<sup>10)</sup>のテーマ(「大阪における降雨現象の有無」)に絞った。深層学習の代表的な機械学習モデルである畳み込みニューラルネットワーク(CNN)を用い、ひまわり7号の赤外雲画像を入力データとして、アメダス大阪観測所における降雨現象の有無を推定するモデルの作成である。入力用の雲画像と教師データは提供して頂いたものを用いたが、プログラムはKeras/Tensorflowを用いて独自に作成した。大阪の降雨の再現については、畳み込み層を2層から3層に増やす、全結合層を2層から1層に減らす、ノード数を減らす、最適化方法を工夫する等、岩井氏が作成したモデルから修正したものを用いて、より高い正解率(約80%;8%向上)が得られた。2017年7月の初旬のことである。そこで次に、高知における降雨現象の有無に関する研究への適用に取り組んだ。

### 3.3 ディープラーニングによる高知市の降水現象の有無の判別

高知市の降水現象の有無の推定モデルの作成に



図2. 学習に使用した雲画像の例

表2. 高知の降水現象推定のための学習条件

学習回数	30回
入力画像サイズ	17,433×200×200×3
バッチサイズ	64
最適化方法	Adam
各層の活性化関数	ReLU 関数
出力層の活性化関数	softmax 関数

については、データの自動ダウンロード、画像の切り出し、RGB画像からグレースケール画像への変換、複数グレースケール画像による多チャンネル画像の作成、Kerasによる降雨推定モデルの作成、学習済みモデルによる降雨推定の全てのPythonプログラムを自作した。プログラム作成は主に若槻が担当した。図1に用いたCNNの構成を示す。

使用したひまわり7号赤外画像と、200×200画素を切り出してグレースケールに変換した画像の例を図2に示す。学習に用いた入力画像<sup>11)</sup>は2013年及び2014年における西日本エリアの赤外衛星写真を中四国地方の範囲で200×200ピクセルのサイズに切り出し、グレースケールに変換したもの(図2右上段の画像)を17,435枚用意した。

そして、1時間異なる時刻の画像を3枚組み合わせた3チャンネルRGB画像(図2右下段の画像;200×200×3)を作成し、17,433個の入力データとした。なお、図2の3ch画像は他の2画像と異なる時刻のものである。

17,433個の入力データおよび教師データ(アメダスデータに基づく、降雨現象有り、降雨現象無し)のデータを80%の訓練データと20%のモデル検証用のテストデータにランダムに分割し、表2の設計のCNNを用いて推定モデルを作成した。その結果、図3に示すように、正解率が87%以上に達した。以上の成果は、高知工科大学永国寺キャンパスで開催された日本環境共生学会20回記念(2017年度)学術大会(9月22~24日)の発表論文集<sup>12)</sup>に

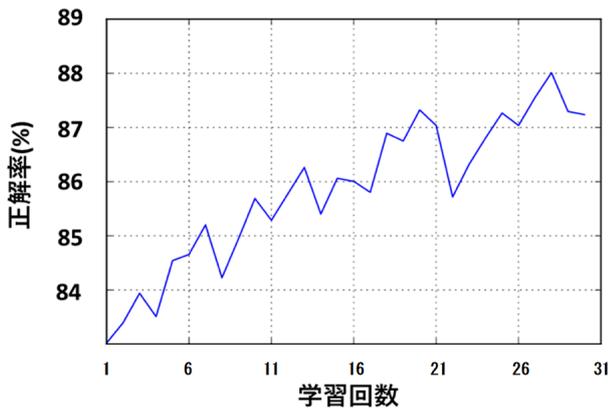


図 3. 学習による降水現象有無の正解率の変化

掲載されている。

### 3.4 多層パーセプトロンによる早明浦ダム流入量の推定

ひまわり7号雲画像データについては、降水現象の有無だけではなく、降水量の推定も試みた。降雨現象の有無の推定では満足できなかったからである。一つの手法として、降水量をいくつかのレベルに分けて、CNNによる画像分類の手法をそのまま用いる試みを行ったが、観測結果との相関が良くなかった。ひまわり7号赤外画像の輝度と降雨量との定量的関係が良くないことが理由と考えている。

試行錯誤の中で、降雨現象に関連した定量的な予測を機械学習・深層学習によって行うことのできるテーマに取り組みたいと考えようになった。また、降雨に関する大量のデータと環境問題にとって重要な物理量との間の推定モデルを作成したいとも考えた。データ探索の結果、早明浦ダムの上流流域圏平均雨量、ダムへの流入量、放流量、貯水量等の1時間値が、国土交通省の水文水質データベースとして公開されていること<sup>13)</sup>が確認できた。早明浦ダムは「四国のいのち」と呼ばれている重要なダムであるため、意義があると判断して研究に着手した。

問題は、Kerasによって「分類」ではなく「回帰」をどのように実装するかであるが、その情報は容易には見つからなかった。ほとんどの教科書やホームページで扱っている手法は分類であった。そのなかで、2017年4月に出版された“Deep Learning with Keras”に“regression network”の項目があり、様々な大気汚染物質濃度を入力データとしてベンゼン濃度を推定する回帰の例が掲載されていた<sup>14)</sup>。余りにも単純な例であったが、次の重要な情報が得られた。Kerasでは、分類においては通常、各カテゴリーに

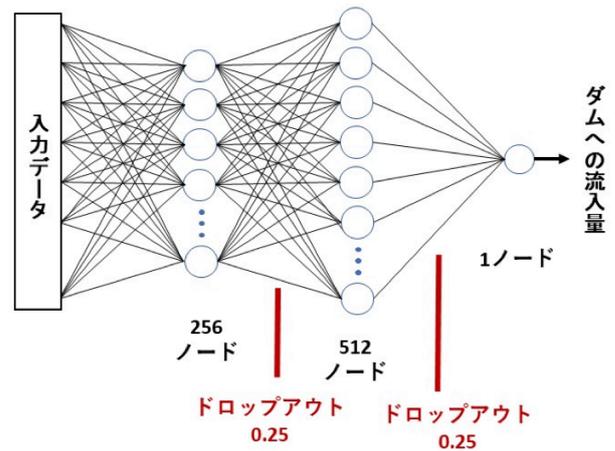


図 4. 学習に用いた多層パーセプトロンの構造

対応する確率を計算するために次の行、

```
model.add(Activation("softmax"))
```

が必要であるが、回帰の場合にはこの行が必要ないこと、誤差は“categorical crossentropy”ではなく“mean squared error”によって評価すれば良いことである。この情報を基に、ダム上流流域圏平均降水量の1時間値の時系列データ（96時間あるいは120時間）114,550個を入力データとして、ダムへの流入量を教師データ（推定すべきデータ；出力データ）として選択してプログラムを作成した。学習には多層パーセプトロン（MLP）を用いた。画像の特徴抽出が必要な場合に用いられるCNNと異なり、比較的単純なニューラルネットワークによって良好な学習結果が得られると考えられるからである。用いたMLPの構造を図4に示す。

2017年9月上旬には、120時間の上流流域圏降雨量の時系列のみを入力データとして、ダム流入量の良好な推定モデルが得られた。短期間の降雨によるダム流入量の増加は、主に数時間から数日間の降雨によって起こると考えられるため、120時間の上流流域圏平均降水量を入力データとして選んだことが功を奏したと考えられる。その後、96時間の時系列データで十分であることを確認した。なお、ダムへの流入量は放流の影響を受けること、放流量はダムの貯水量を勘案して決められると考えられるため、入力データとしてダム放流量、ダム貯水量を追加することによって、推定値と実測値の一致の度合いが改善された。この3入力を用いて学習した場合の、モデル推定流量と観測流量の散布図を図5に示す。流入量の大きさにかかわらず、データが原点を通る傾きが1の直線の周りに分布している。ちなみに、入力が上流流域圏平均降雨量の場合の平均二乗誤差平方根（RMSE）は23.947 m<sup>3</sup>/s、ダム

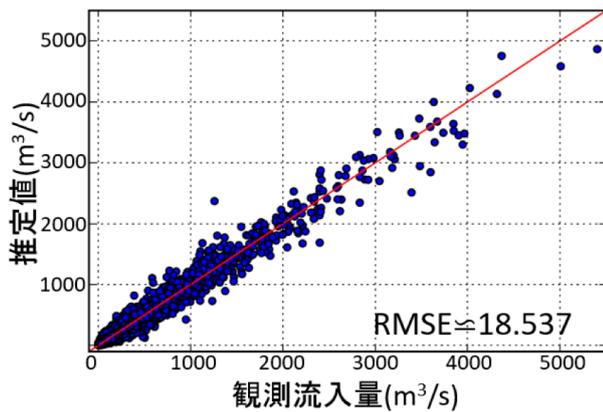


図 5. 上流流域圏平均降水量、ダム貯水量、ダム放流量を入力データとした場合のダム流入量散布図

貯水量を入力に加えると  $19.559 \text{ m}^3/\text{s}$  であった<sup>15)</sup>。

#### 4. 様々なテーマへの展開 (2017 年度後半)

##### 4.1 深層学習による安田川水位推定モデル

若槻を中心に作成された多層パーセプトロン (MLP) および畳み込みニューラルネットワーク (CNN) のプログラムは、入力データと教師データを作成していた各研究テーマの分担者によって応用された。計算機環境構築にかかわってきた修士 2 年生の小島慶之君はダムのない中小河川である高知県安田川の水位の推定に対して MLP を応用した。気象庁が降雨レーダーのデータ等に基づいて作成した  $1 \text{ km}$  メッシュの「解析雨量」<sup>16)</sup> (気象業務支援センターより購入) から切り出した安田川流域圏を囲む領域の雨量の平均値を入力とし、高知県に提供して頂いた東島観測所の水位を教師データとして、MLP による学習を行い、水位推定モデルを作成した。解析雨量の切り出しについては、環境理工学群柴田研究室の中前久美氏に協力して頂いた。以下は、小島慶之君の修士論文<sup>17)</sup>の一部を基にしてまとめたものである。

2006 年から 2017 年 9 月までの 1 時間ごとの解析雨量流域圏平均値 (92,821 データ) の過去 96 時間時系列データを入力データとし、80% を訓練データ、20% をテストデータとして学習し、水位推定モデルを作成した。テストデータに対するモデル推定値と観測水位の散布図を図 6 に示す。水位の高い領域では推定水位と観測水位の一致は良いが、水位の低い領域ではデータが大きくばらついている。

水位の低い場合、すなわち流域圏に数日間降雨のない場合の水位の推定を改善するために、1 か月平均流域圏雨量を 1 年分 (12 データ) の時系列として

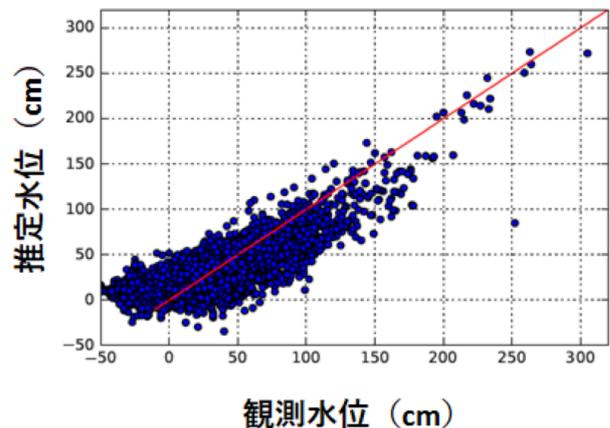


図 6. 安田川流域圏平均雨量 96 時間時系列データを入力データに用いた場合の東島観測水位の散布図

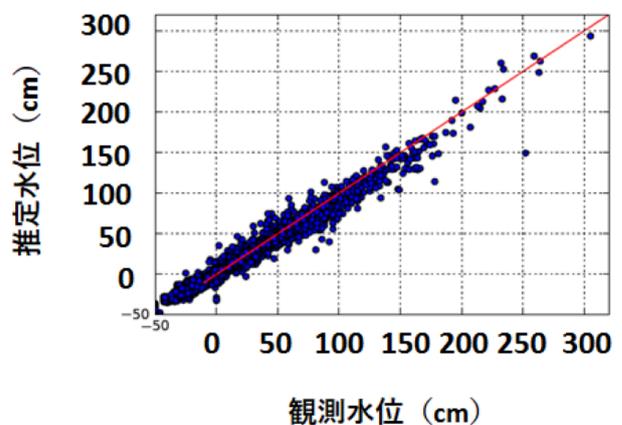


図 7. 安田川流域圏平均雨量 96 時間時系列に加え、1 か月平均雨量の 1 年の時系列を入力データに含めた場合の東島観測水位の散布図

入力データに追加して学習を行い、モデルの検証を行った。図 6 と同様の散布図を図 7 に示す。低水位領域の推定値と観測値の一致が劇的に改善し、負の水位の領域も含めて、データが原点を通る傾きが 1 の直線の周囲にコンパクトに分布している。

図 6 と図 7 の比較の意味するところは、流域圏に数日間雨が降らない場合の水位は、過去数か月の間に降った雨による地下水等による湧水によって保たれているということである。すなわち、ダムのない安田川について「緑のダム」の効果を、深層学習によって示すことができたと考えている。感度解析を行った結果、3~6 か月前の期間の降雨の寄与が大きいことを確認することができた。



図8. 鏡川の概要と宗安寺観測所に関連する情報

#### 4.2 豪雨時の鏡川宗安寺観測所の水位の推定

ダムの流入量の推定のために若槻が作成したプログラムを、ダムのない安田川の水位推定と「緑のダム」の効果の解析の研究に応用しつつ、並行してダムのある支流とダムのない支流からの河川水が流入する鏡川宗安寺観測所の水位推定を行った。2017年度の4年生の林良真君が卒業研究<sup>18)</sup>として担当した。以下は、林良真君の卒業論文の一部に基づいて執筆した。

鏡川は、源流域から河口までが高知市域に入る、延長31km、流域面積170平方キロメートルの二級河川であり、水位周知河川(流域面積が小さく洪水予報を行う時間的余裕がない河川)に指定されている。また、台風12号および台風11号の影響を受けた2014年8月豪雨の際には、宗安寺観測所においても記録的水位が記録された。そして、高知市全域に避難勧告が出された。このような特徴を持ち、高知市民にとって重要な河川において、4m以上の水位の記録がない2009年1月1日～2014年7月31日の降雨量、ダム諸量、宗安寺観測所水位データに基づく学習によって作成した水位推定モデルが、2014年8月1日～8月10日の水位をどの程度正確に推定できるかについて検討した。

図8は、高知県のホームページに基づき作成した鏡川と宗安寺観測所に関連する情報をまとめたものである。この図に示されるように、宗安寺観測所の水位は、鏡ダムを經由して鏡川に流れるダム集水範囲に位置する黄色エリアと、鏡ダムを經由せずに鏡川に流れる緑色エリアの降雨量と、鏡ダムの影響を受ける。この研究では、各入力データの寄与の解析より、一種の外挿可能性の検討に重点を置いているため、宗安寺観測所水位に関連する、欠測の少ない河川情報および全てのダム諸量を入力データ

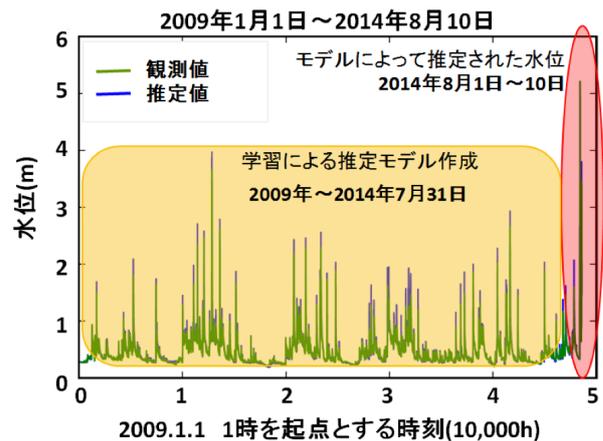


図9. モデル作成期間および水位推定期間の宗安寺観測所の水位。下段の図は、上段右端8月1日～10日の期間を拡大したもの。

として用いた。具体的には、平石降雨量(73時間の時系列)、柿の又降雨量(73時間の時系列)、宗安寺降雨量、鏡ダム流入量・鏡ダム全放流量・鏡ダム貯水量、柿の又月平均降雨量(1～9カ月の時系列)を入力データとし、宗安寺観測所水位を教師データとした。学習による推定モデル作成には、2009年1月1日～2014年7月31日の期間を用い、2014年8月1日～8月10日の入力データを用いてこの期間の宗安寺観測所の水位を推定した。図9に宗安寺観測所の観測水位とモデル推定水位の時系列を示す。

図9上段に示すように、水位推定モデル作成に用いた期間の最大水位は4m以下であるにもかかわらず、8月3日の約5mの宗安寺観測所の水位を良好に推定している。また、台風12号と台風11号が続いて接近して発生した、豪雨による水位の時系列の全体像も良く再現している。通常、帰納的手法による外挿は困難とされているが、想定範囲内であれば、入力データを注意深く扱うことによって外挿も可能であることを示すことができたと言える。

1級河川について、洪水時に着目し、深層学習を



図 10. 樹種判別に用いたドローン空撮画像。左上のオレンジ色の正方形は、樹種判別に用いた 100 × 100 ピクセルの個別の画像。

含む機械学習によって高い精度の予測が可能であることを示した例が報告されている<sup>19)</sup>。この研究では、洪水時のみの数時間の雨量の時系列データを入力データとして用いている。それに対して、本報告で紹介している早明浦ダム流入量、安田川水位、鏡川水位を対象として実施している、低水位期間の降水量のデータも含めた全期間の大量の入力データを用いた研究は、深層学習の特長を活かし、洪水期間も渇水期も含めた河川の水文過程全体を切れ目なくモデル化する試みとして独自性の高い研究であると考えている。現在は中小河川を対象にしているために、入力データが得られない将来の予報について言及していないが、大河川の場合には河川データのみによって予報が可能であると考えている。また、解析雨量の予報値を用いるならば、中小河川についても数時間の予報が可能であることを示唆する結果が得られていると考えている。

#### 4.3 ドローンによる空撮画像と転移学習による森林の樹種判別

高知の降水量の有無の判別に用いた畳み込みニューラルネットワーク (CNN) のプログラム、“Deep Learning with Python”<sup>9)</sup>等の書籍、ホームページからの情報等を参考にしつつ、2017年度4年生の明田啓暉君は3種類のユリ科植物、「ヤマユリ」、「オニユリ」、「ウバユリ」の花の分類を行うプログラムを作成した<sup>20)</sup>。この研究の中では、1000個のカテゴリに分類するための画像データベース“ImageNet”で学習した重みを使うことのできる Xception モデル<sup>20)</sup>を用いた転移学習 (fine-tuning) を用いて、100%の正解率を得た<sup>21)</sup>。このプログラムを用いて、2017年度4年生の増本雄大君はドローン空撮画像の判別を

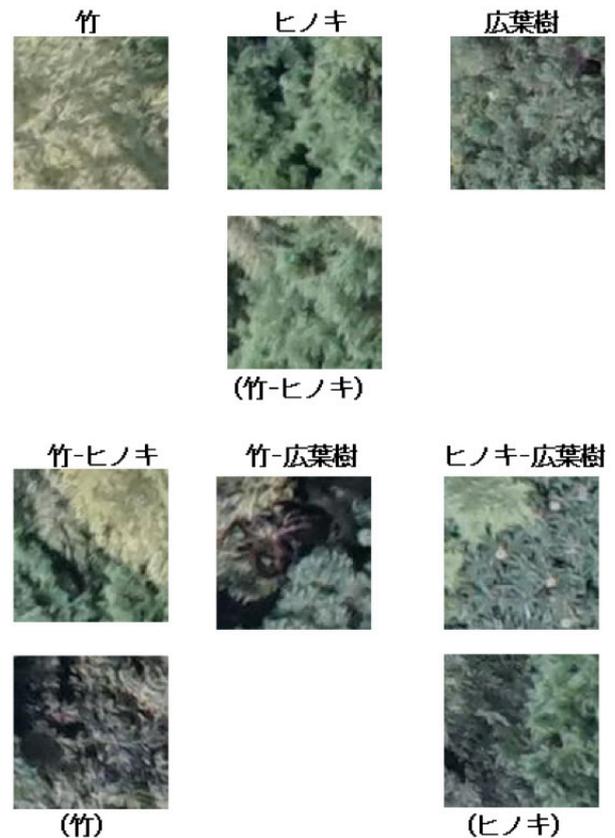


図 11. 各カテゴリーの典型的な画像 (上段) と不正解画像例 (下段)。( ) 内は学習済みモデルの判断。

行い約 90%の正解率を得た<sup>22)</sup>。さらに、明田君と2018年度4年生の山本啓君がプログラムの見直しを行い、2018年4月現在、98%以上の正解率を得ることができている。以下に、3名の中根研究室学生の成果の一部を紹介する。なお、Fine-tuning、Xceptionによるプログラミングは、“Keras Documentation”<sup>8)</sup>を参考にして行った。

空撮画像は、高知工科大学地域連携機構の村井亮介研究員がドローンに装着したカメラで撮影したものを、高知工科大学システム工学群の高木方隆教授を通して提供して頂いた。今回使用した森林画像は、高知県香美市土佐山田町の佐岡地区の森林の一部を撮影した動画の1枚を静止画として取り出したものである。使用した画像を図 10 に示す。横 6000 ピクセル、縦 4000 ピクセルの画像である。この画像から 100×100 ピクセル (2.4m×2.4m) の画像を 2400 枚切り出し、「竹」、「ヒノキ」、「広葉樹」、「竹—ヒノキ混合」、「竹—広葉樹混合」、「ヒノキ—広葉樹混合」、「影」の7カテゴリーに分類した。それぞれの画像を 90 度、180 度、270 度回転させた画像を加えて 9600 画像にした後、80%の訓練画像と

20%のテストデータにランダムに分割し、400回の学習をほぼ1日かけて行った。テストデータの正解率は98.75%であった。

作成した学習済みモデルを用いて、テストデータの中の回転する前のオリジナル画像に対する樹種判別を行ったところ、正解は475画像中469画像で、正解率は98.74%であった。回転したテスト画像に対する正解率とほぼ等しい。典型的な正解画像と不正解画像例を図11に示す。ヒノキの不正解画像のように、深層学習によって作成された学習済みモデルの判断の方が人間の判断に勝ると考えられる例もある。

98.7%を超える正解率は極めて高いが、1枚のドローン空撮画像に含まれるテストデータによる検証の結果であり、作成された学習済みモデルを他の空撮画像について樹種推定を行った場合には正解率が低下する可能性がある。「広葉樹」の具体的な中身が場所によって異なるからである。2種類の樹種の「混合」というカテゴリーがあることも問題である。さらに、真に適切な教師データ（樹種判別）ができていないか、については専門家の判断に頼る必要があるが、専門家の負担を小さくするために、オートエンコーダーの利用等についても検討する必要があると考えている。

#### 4.4 畳み込みニューラルネットワークによる回帰

これまでの例から、畳み込みニューラルネットワーク（CNN）は分類、多層パーセプトロン（MLP）は回帰と分担が決まっているような印象を持つ向きがあるかも知れない。しかし、CNNもMLPも分類、回帰のどちらにも使用できる。

中根研究室においても、2017年4年生の松浦栄理さんが、ひまわり7号の可視雲画像から全天日射量の推定モデルを作成し、雲量の多い場合を除いて良好な再現が可能であることを確認した<sup>23)</sup>。市街地と雲の輝度が同じように高いことが雲量の多い場合の誤差もたらしていると考えられる。ひまわり8号のいくつかのチャンネルを組み合わせた画像を使用する等により、改良が可能であると考えている。

## 5. おわりに

世の中は解決したい課題で溢れているが、解決するための技術は多くの専門分野に細分化され、精緻さを競っている。本質を把握すれば、なるべく汎用性の高い技術によって課題の解決に近づけないか、と常々考えてきた。その時、深層学習（ディープラーニング）に出会った。大きな可能性を感じた。

2016年は、それ程のコストをかけることなく深層学習のための計算機環境を整備することが可能になった時期であったことは幸いであった。

私達はたまたまKeras/Tensorflowのフレームワークを用いて深層学習用のプログラムを作成したが、Chainerやその他のフレームワークでも同様の成果が得られたかもしれない。これらの多様なオープンソースを開発して下さった技術者たちに、心から感謝したい。この報告書においてなるべく具体的に詳細な記述を心がけたのは、少しでもお返したい、これから深層学習に取り組む方々のお役に立ちたいと考えたからである。このオープンソースの生態系が「共有地の悲劇」の対象になるのではなく、多様性を持った持続可能な生態系であり続けることを願っている。また、この生態系が、人間社会にとって、持続可能性を支える重要な構成部分であることを願っている。

この研究に貢献した教員、研究者、学生は余にも多い。本報告はプロジェクト立ち上げに関する報告であるため、立ち上げそのものに関わった中根と若槻が代表して報告させて頂いた。関係者のご理解を賜れば幸いである。

## 謝辞

深層学習に取り組むきっかけを作ってくださった大阪大学三宅淳教授と三宅研究室の皆様深く感謝します。「このような問題に、このように取り組めば、このような結果が得られる」という具体例やデータを示して頂いたお陰で、プロジェクトを軌道に乗せることが可能になりました。

実際にデータを吟味し、プログラムを改良して様々なテーマに取り組んで下さった、中根研究室大学院生、学生の皆さん、小島慶之君、明田啓暉君、林良真君、増本雄大君、松浦栄理さんによって、この研究分野の多様な可能性を示すことができました。ありがとうございます。

河川に関してご教示頂いた高知工科大学経済・マネジメント学群那須清吾教授、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った、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。ドローン空撮画像と画像に関する情報を提供して下さった、システム工学群高木方隆教授、赤塚慎准教授、地域連携機構村井亮介研究員に感謝いたします。また、河川データを提供して下さった高知県土木部河川課のご協力があって、初めてこの研究が可能になりました。お礼

を申しあげます。

気象データ、河川データに関わる観測、整備等に携わる方々なしにはこのような研究はあり得ませんでした。深く感謝する次第です。

本研究を行う場を与えて下さった高知工科大学にはお礼の申しようもありません。なお、本研究の一部は、「SI-CAT 気候変動適応技術社会実装プログラム」の一環として実施されております。

## 文献

- 1) 情報処理推進機構, “第 1 章 技術動向”, AI 白書 2017, pp. 15–166, 2017.
- 2) 高知工科大学環境理工学群ホームページ, “理工学のフロンティア”, URL = <http://www.scsci.kochi-tech.ac.jp/frontier.html>
- 3) J. Miyake, Y. Kaneshita, S. Asatani, S. Tagawa, Shimoda, H. Niioka and T. Hirano, “Graphical classification of DNA sequences of HLA alleles by Deep learning”, Human Cell, published online, URL = <https://link.springer.com/article/10.1007/s13577-017-0194-6>, 2018.
- 4) H. Niioka, S. Asatani, A. Yoshimura, H. Ohigashi, S. Tagawa, and J. Miyake, “Classification of C2C12 cells at differentiation by convolutional neural network of deep learning using phase contrast images”, Human Cell, published online, URL = <https://link.springer.com/article/10.1007%2Fs13577-017-0191-9>, 2017.
- 5) 岩井尚晴, 浅谷学嗣, 田川聖一, 新岡宏彦, 三宅淳, “ニューラルネットワークを用いた日平均気温の予測”, 気象学会 2016 秋季大会予稿集, 2016.
- 6) 藤田一弥, 高原 歩, “実装 ディープラーニング”, オーム社, 2016.
- 7) Qiita, “TensorFlow が正式に Windows サポートして GPU が使えたので試してみた”, URL = <https://qiita.com/tilfin/items/24e9491eb8a4ce42eea6>, 2016.
- 8) Keras Documentation ホームページ, URL = <https://keras.io/ja/>.
- 9) F. Chollet, “Software/hardware requirement”, Deep Learning with Python, Manning, 2018.
- 10) 岩井尚晴, “気象に対する Deep Learning の応用—100~1000 km 圏の解析—”, 大阪大学基礎工学部システム科生物工学コース三宅研究室平成 28 年度卒業論文, 2017.
- 11) 日本気象協会ホームページ, “過去天気”, URL = [http://www.tenki.jp/past/2013/01/?selected\\_type=satellite](http://www.tenki.jp/past/2013/01/?selected_type=satellite).
- 12) 若槻祐貴, 小島慶之, 中根英昭, 岩井尚晴, 田川聖一, 新岡宏彦, 三宅淳, “ディープラーニングの環境分野への応用—降水現象を例として—”, 日本環境共生学会第 20 回記念 (2017 年度) 学術大会論文集, pp. 1–6, 2017.
- 13) 国土交通省, “国土交通省水門水質データベース, 任意期間ダム諸量検索—”, URL = <http://www1.river.go.jp/cgi-bin/SrchDamData.exe?ID=1368080700010>.
- 14) A. Gulli and S. Pal, “regression network”, Deep Learning with Keras, pp. 223–228, Packt, 2017.
- 15) 若槻祐貴, “ディープラーニングによる高知市の降水現象の有無の判別と早明浦ダムの流入量推定”, 高知工科大学環境理工学群平成 29 年度卒業論文, 2018.
- 16) 気象庁ホームページ, URL = <http://www.jma.go.jp/jma/kishou/known/kurashi/kaiseki.html>.
- 17) 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.
- 18) 林良真, “深層学習による高知市鏡ダム下流宗安寺観測所の水位推定モデル”, 高知工科大学環境理工学群平成 29 年度卒業論文, 2018.
- 19) 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.
- 20) F. Chollet, “Xception: Deep Learning with Depth-wise Separable Convolutions”, URL = <https://arxiv.org/abs/1610.02357v3>, 2017.
- 21) 明田啓暉, “深層学習/転移学習を用いた 3 種のユリ科の花の判別”, 高知工科大学環境理工学群平成 29 年度卒業論文, 2018.
- 22) 増本雄大, “転移学習を用いたドローン空撮画像による樹種判別”, 高知工科大学環境理工学群平成 29 年度卒業論文, 2018.
- 23) 松浦栄理, “深層学習 (CNN) による高知の全天日射量推定モデル”, 高知工科大学環境理工学群平成 29 年度卒業論文, 2018.

# Startup of Deep Learning Application to Environmental Research

Hideaki Nakane<sup>1\*</sup> Yuki Wakatsuki<sup>2</sup>

(Received: May 7th, 2018)

<sup>1</sup>School of Environmental Science and Engineering, Kochi University of Technology  
185 Miyanokuchi, Tosayamada, Kami City, Kochi 782–8502, JAPAN

<sup>2</sup>Graduate School of Engineering, Kochi University of Technology  
185 Miyanokuchi, Tosayamada, Kami City, Kochi 782–8502, JAPAN

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

**Abstract:** We implemented a computing environment for deep learning, a form of artificial intelligence technology, at the Nakane Laboratory in the second half of FY 2016. In FY 2017, deep learning technologies were successfully applied to various environmental research themes. We developed regression and classification models for the following targets. For regression, we used the amount of inflow into the Sameura Dam, the water level of the Yasuda River, the water level of the Kagami River, and the total amount of solar insolation in Kochi. The targets of classification were the presence / absence of precipitation in Kochi, three species of flowers / lilies, and forest tree species. Although our objective is diverse, we could create estimation models using two kinds of deep learning methods; multilayer perceptron (MLP) and convolutional neural network (CNN). In regression cases, it was shown that the water levels and the inflow amounts to the dam during entire periods from flooding to droughts can be well predicted using the MLP models. The CNN models with transfer study demonstrated performance equivalent to or better than humans for classification of tree species.