

深層学習を用いた油圧ショベル自動制御システムの開発事例

油圧ショベルが無人かつ自律的に施工を行う現場を目指して

西村 弘平・富山 翔司

近年、建設業界では、働き手不足が深刻化しており、作業現場の省人化や無人化のニーズが高まっている。ICT技術により作業効率化を支援するICT建機の導入が一部で進んでいるが、既に流通する建機への後付けが難しく、高額であること等から、作業現場での省人化はまだ十分進んでいない。また、特に、作業現場でよく用いられる汎用重機である油圧ショベルは、油圧に起因する動作の再現性の低さや強い衝突による挙動の不安定さ等のため従来制御では自動化が困難であった。本稿では、これまで困難であった作業現場のさらなる省人化や無人化に向けて、機体に安価なセンサーと遠隔操縦装置のみを後付けで設置し、深層学習を用いて、油圧ショベルを無人で自動制御するシステムについて紹介する。

キーワード：AI, ICT, 土工, 機械化施工, 無人化施工

1. はじめに

近年、建設業界は働き手不足が深刻化しており、生産性向上が喫緊の課題となっている。少子高齢化が進む日本では、生産年齢人口が1995年の8,716万人をピークに下がり続けており¹⁾、さまざまな産業で働き手不足が顕在化してきている。特に建設業界は、他の業界と比べて働き手不足が深刻である。職業の需給状況を示す新規求人倍率について、2018年の「建設業界」の値は6.85倍(前年同期は6.08倍)であった。これは、全職業平均の2.25倍(前年同期は2.21倍)より高い²⁾。出生率が低迷し、移民が限定的であるため、働き手が求人に対して十分増加する可能性は低い。そのため、働き手不足に対応し、業界を維持するためには、生産性向上が必須である。

生産性向上の試みとして、ICT技術を用いることで、「調査・測量」、「設計・施工」、「検査」、「維持管理・更新」の建設現場の各プロセスで省人化を進める試み(i-Construction)が進められている。i-Constructionの取り組みの1つであるICT施工は、ICT技術により各作業の情報をデジタルデータとして管理し、高効率・高精度な施工を目指すものである。例えば、ICT技術を活用して現場作業の効率化を図る建機として、ICT建機がある。ICT建機³⁾とは、汎地球測位航法衛星システム(Global Navigation Satellite System, 以下GNSS)やトータルステーション(Total Station, 以下TS)といった高精度測位技術を活用して、オペレー

ターに操作のガイダンスを行う機能(マシンガイダンス, 以下MG)や、重機の刃先の自動制御を行う機能(マシンコントロール, 以下MC)がついた建機である。オペレータはICT建機を用いることで、設計図面や現況および重機の状態等の情報により算出された、MGやMCに基づいて施工できる。そのため、手戻りが少なく精度の高い施工ができるようになるという点で、ICT建機は、現場の作業効率化に貢献してきた。例えば、ショベルは掘削・積込・整地・運搬などの作業ができる汎用的な重機であり、一部の作業は難しく、熟練に年数を要するものもある。しかし、MG, MC機能を搭載したICT建機を使用することで、新人のオペレーターでも難しい作業を短い作業時間で行えるようになるということもあり、現場の生産性をあげることができる。

しかし、作業効率化を目的としたICT建機の利用には課題もある。1つ目は、ICT建機は高額なセンサーを搭載しており、ICT建機を利用しない施工よりもICT建機を利用した施工の方が、施工費が高い点である。つまり人数に対する仕事量は効率化されるものの、金銭的成本に対する仕事量は効率化されず利用が進みにくい場合があるということである。2つ目は、通常建機を後付けでICT建機にすることが難しい点である。すでに現場では多くの建機が流通利用されている。それらにICT建機の機能を付与することは難しく、また、買い替えコストも大きいため、利用する建機のICT化が進まない一因となってい

る。3つ目は、ICT 建機を利用しても、作業の無人での自動化を実現できない点である。ICT 建機の ICT 関連機能はオペレーターの操作を支援することを目的として設計および開発されており、オペレータの操作なしでは動作しない。そのため、現場作業の効率化には寄与するが、自動化には寄与しない点で、効率化は限定的である。

本稿では、深層学習を活用した油圧ショベル自動制御システムの開発事例を紹介する。本システムは、油圧ショベルの作業の無人での自動化を安価なセンサーのみを利用して実現することを目指したものである。ショベルの作業の無人での自動化が実現できれば、建設現場の省人化および無人化がより進むことが期待できる。例えば、ある範囲を1m掘り下げるという指示を与えるだけで、その作業が無人かつ自動化で実現できれば、本来その作業をするはずだった人が、他の作業に集中できる。また、安価なセンサーのみで自動化が実現できれば、施工費を抑えられる可能性がある。本システムは、制御の入力にRGBカメラと1つの傾斜計のみを用いている。更に、本システムは多くのメーカーの機種 of ショベルに後付けできるようにすることを狙って、様々なショベルに取り付けることができる遠隔操作技術を利用した開発を行っている。

従来技術を活用した場合、こうした無人での自動制御システムの実現には、RGBカメラから制御に必要な情報を抽出する画像認識機構と、土との抵抗がある中での自動制御機構に課題があった。具体的には、認識機構については高次元データである画像から低次元の情報のみを抽出するモデルの設計が難しかった。また制御機構については、異なる土の状態に適応的に制御を行うことが難しかった。この2つの課題は、モデルの設計方法が難しかったり、多様な場合に全て対応するようにモデル設計しきることが困難であったりしたために、従来技術での解決は限定的であった。例えば、画像認識の従来技術では、画像から欲しい情報を抽出するためのフィルタや特徴量を人手で設計していたが、さまざまな背景や多様な光源環境に対しても頑健なモデルを人出で設計しきことは困難であった。また、制御の従来技術の代表例であるPID制御では、3つのパラメータで制御を行うが、この制御モデルはパラメータが有効な一部の限定的な土の状態でしか有効な制御が行えない。

以上の問題に対して、本稿で紹介するシステムでは深層学習を用いることによって解決を試みている。深層学習モデルは任意の関数を表現でき、大量の学習データがあれば、時系列情報や画像情報も有効に扱う

ことができる。そのため、背景や光源等が多様であっても目的の情報を画像から抽出できる画像認識モデルや、さまざまな土の環境に応じて適応的に動かし方を制御できる制御モデルを、得られる可能性がある。本システムでは具体的に、画像からショベルの各関節角度を推定するモデルと、常に変化する土の環境で適応的に制御ができるモデルを、深層学習によって獲得している。

本項では、深層学習について説明をした後、ショベル自動掘削システムの詳細と、各機構の評価結果について説明する。最後にショベル自動掘削システムの今後の開発方向性を述べる。

2. 深層学習

深層学習とは、人間の脳神経回路を参考にして、ニューラルネットワーク（以下、NN）を多層に積んだモデルを用いた機械学習手法である。NNの各層では、前の層のニューロンの線形変換と活性化関数による非線型変換が行われ、これを多層に積み上げることによって、高い表現力を獲得することができる。

深層学習は、画像や言語といった高次元の情報や系列情報を容易に取り扱うことができ、画像認識や自然言語処理の研究分野では人間の性能を超えるような目覚ましい成果を挙げているタスクもある^{4), 5)}。深層学習は制御にも応用されている。数式でのモデリングが難しいような状況での制御（例えば物体と接触するような時）をする上で、深層学習によって環境モデルや制御関数を学習することにより、その高い表現力を持ってして今まで制御できなかったような動作を習熟することが可能になってきている⁶⁾。

画像データに特化した深層学習技術として、CNN（Convolutional Neural Network, 以下CNN）がある。CNNは畳み込みと呼ばれる演算を繰り返し行うが、各畳み込みではフィルタと呼ばれる格子状の重みがデータの局所的な特徴（例えばエッジ）を抽出していき、それが積み重ねられることで画像全体の情報が抽出される。CNNは、同じ重みのフィルタを画像全体にかけるため、画像の特徴的な部分が画素上のどこにあってもうまく特徴を抽出できる、位置普遍性を持っており、これが画像データをうまく扱える理由とされている。学習過程ではこのフィルタの重みが自動で決定されていく。CNNは、物体カテゴリ識別⁴⁾、物体検出⁷⁾、物体領域抽出⁸⁾など様々な画像入力の問題設定で精度高い結果が出せることが示されてきた。

また、制御の分野で頻繁に応用されている深層学習

技術として、深層学習と強化学習を組み合わせた深層強化学習がある。強化学習とは、あらかじめ用意された環境と報酬の中で、エージェントが環境内での試行錯誤を繰り返していき、報酬を最大化するような動き（方策）を学習する機械学習手法である⁹⁾。ここに深層学習を利用することによって、複雑な動作をする方策を学習することができるようになる。既に囲碁やゲームでは、人間を超えるようなエージェントの学習ができるようになっていて、グラスピングなどのロボティクスのタスクでも、今までにできなかったような複雑なタスクができるようになってきている^{10), 11)}。一般的に、深層強化学習は、教師信号を必要とせず、環境内で試行錯誤によって学習するために、膨大な試行回数を必要とする。

3. ショベル無人自動制御システム

(1) ショベルの自動制御システムの構成

本システムは、作業領域と作業内容が与えられた時、画像と傾斜計のセンサ値のみを制御入力として、その作業内容を無人で自動制御することを目指している。生の画像データから操作信号を直接出力することは難しいため、本システムでは、画像データから制御に必要な情報（＝ショベルの各関節角度）を抽出する状態推定機構と、与えられた作業内容を実現するための操作信号を出力する制御機構の二つを開発し、これらをつなぎ合わせている。制御周期は10 Hzとしている。

自動制御のシステムを構築するために必要な機材は、ショベルの機体に設置する機材と遠隔にある操作室に設置する機材の2種類がある。ショベルに設置する機材は、遠隔操縦装置、ハイビジョン規格のRGBカメラとカメラの無線送信機、傾斜センサとセンサー情報の無線送信機である。遠隔にある操作室に設置する機材は操縦装置のコントローラー、カメラ画像の無線受信機、傾斜センサーの無線受信機、カメラ画像からの情報抽出と制御の処理を行う計算機である。RGBカメラはキャビン上部に設置する。写真—1はカメラの設置箇所を撮影した写真であり、本システムではいずれか1つのカメラを用いる。必要な機材は、すべて多数のメーカー、機種ショベルに設置できるものを使用しており、さらにショベルに設置する機器が車などで簡便に運搬できるため、既存の重機に対する導入コストは少ない。より多くの重機に対して、少ないコストで導入できる無人の自動制御システムは現場の生産性向上に大きく寄与する。



写真—1 カメラの設置箇所の様子


なお、本システムを用いた無人自動制御をする作業の対象として、掘削を選定した。掘削はショベルの作業の中でも頻繁に行われる作業だが、土の抵抗があるために自動制御が難しかった作業でもあり、無人自動制御が達成されることによる貢献が大きいと判断したためである。

(2) ショベルの状態推定機構


ショベルの状態は図—1に示す5つの角度によって一意に定まるので、この5つの角度が制御に必要な情報である。ショベルの機体全体の傾きは傾斜センサーによって取得できるため、本システムの状態推定機構ではキャビン上部に取り付けたカメラ画像からショベルの3つの各関節の角度を推定する。写真—2は実際に認識した結果の一例である。

カメラ画像からショベルの関節角度を推定する機構では深層学習を用いている。この機構は、ノイズに対して頑健に、画像から適切な情報を抽出する必要がある。深層学習は、高い表現力が必要なモデルを表現でき、画像のような高次元のデータから低次元のデータを抽出することができる。

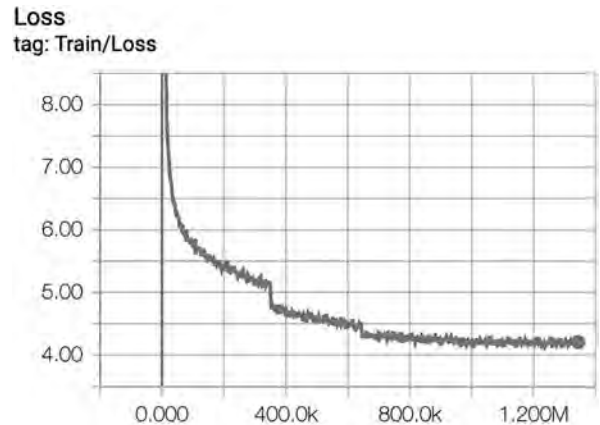
ショベルの状態認識機構では、Dilated Residual Networks¹²⁾（以下、DRN）というネットワーク構造をベースにして関節角度を直接推定するCNNを用いている。DRNは物体カテゴリ識別、物体領域抽出でよい性能をあげたことが報告されているCNNの手法の1つであり、ショベルのキャビン視点画像からショベルの関節角度を推定する機構においても有効であった。ショベルの状態推定ではCNNが画像を入力とし



図一 ショベルの状態を表す角度の図 (左: ショベルを横から見た図, 右: ショベルを後ろから見た図)



写真一 認識機構で状態認識をした結果の例 (左上: 横カメラの画像, 左下: キャブ視点画像から推定した結果, 右: キャブ視点カメラの画像)



図二 CNN 学習時の誤差関数のプロット図 (横軸はエポック数, 縦軸は誤差関数の値)

て3つの角度を出力する。CNNは各関節角度が出力する角度が360クラス(1クラスは1度に対応し、1度から360度までの360クラス)のどのクラスであるかの分類問題を解き、各関節の角度を整数値で出力する。

10 Hzの制御周期で制御するためには、状態推定のCNNは0.05秒程度で状態を推定する必要がある。CNNの入力に用いる画像の解像度が大きいと、CNNのパラメータ数が増えるため推定にかかる時間が長くなる。CNNの処理高速化のためには、角度推定の精度が落ちない範囲で入力画像の解像度を小さくする必要がある。本システムで利用しているカメラは、解像度が1,280 × 720のハイビジョン規格のカメラであるが、CNNの処理を高速化するために、解像度を224 × 224に圧縮している。

CNNの学習は一般的な学習方法である教師あり学習で行い、約100万件のキャブ視点画像と正解角度のペアを用いた。キャブ視点画像に対応する各関節角度のデータ作成は以下の4ステップからなる。まず、ショベルの各関節間の距離を測定する。次に、ショベルのキャブ視点と真横にカメラを設置し、それらのカメラ間で同期を取りながら、ショベルを適当に操作

し、データ収集を行う。そして、横視点カメラ画像の関節点の座標を手でラベルづけする。最後に、ブームに取り付けたARマーカーによって関節点の3次元空間座標を推定し、各関節の角度を計算する。以上の4ステップを踏まえてキャブ視点画像に対する関節角度データを作成した。

CNNの誤差関数は、クロスエントロピーというクラス分類の問題設定でよく使われる誤差関数を用いており、学習にかかる時間は3～4日程度である。訓練時の誤差関数のグラフを図二に示す。

(3) ショベルの制御機構

制御機構は、作業内容が与えられた時、それを実現するための操作信号を、各関節角度と傾斜計のセンサ値を入力として推定する。掘削の作業には、移動と旋回は含まれないので、実際にはブーム・アーム・バケットの3関節のみの操作を制御する機構の開発を行った。

制御方策の学習には、深層強化学習を用いている。制御方策の学習方法として、対象作業を行うオペレーターの操作ログを用いて教師あり学習を行うという方法が考えられる。しかし、教師あり学習による制御方策の学習は、教師データの作成に実機を使うために非

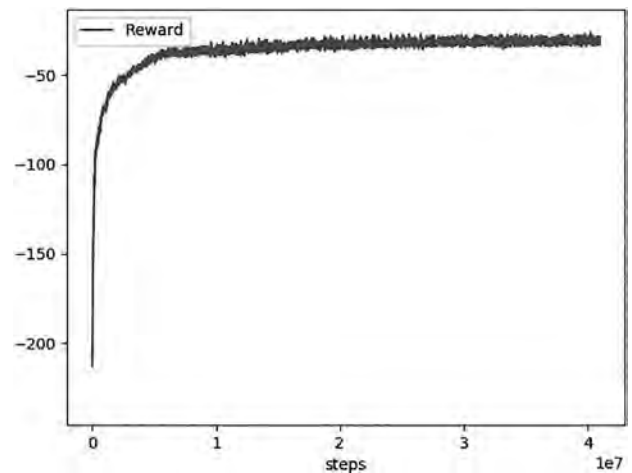
常に手間がかかる。また、制御対象の作業ごとに教師データの作成と制御方策の学習を行う必要がある。そのため、教師あり学習は現実的な学習方法ではない。深層強化学習を用いることによって、教師となる操作量のログデータを必要とせずに、複雑な動きを学習することができる。

制御方策の学習にはシミュレーターを用いている。深層強化学習を用いて習熟した操作を学習するには、数百万を超えるような試行回数を必要とすることが稀ではなく、それだけの試行を油圧ショベルで行うことは、機体の耐久性、実験場の設備、学習に必要な時間、といった観点から現実的ではない。そのため、シミュレーターを用いて掘削の制御モデルを学習する。シミュレーターを用いることで、何百万回という試行を容易に行うことができ、深層強化学習の実現を可能とする。

シミュレーターを活用する際の問題として、現実世界の物理挙動とシミュレータの物理挙動が異なることが挙げられる。この差を埋める方法として、現実世界の物理挙動の観測からシミュレータの物理挙動を近づける方法が考えられるが、前述の通り、油圧の挙動や土の中の挙動は単一の数式によって表現できず、現実世界の挙動をシミュレータ上で似せること自体が難しい。そのため、Domain Randomization という手法を用いて、現実世界とシミュレータの物理挙動の差を埋めた。Domain Randomization では、物理挙動を規定するシミュレータのパラメータを毎試行ごとに幅広い範囲でランダム化し、制御方策をその中で学習させる。これによって、どんな物理挙動をする空間でもうまく制御できる方策を学習でき、実機に転用することが可能になる⁹⁾。本システムにおいては、土の抵抗や重機の重心、遅延の関係などを試行ごとにランダム化し、その環境の中で学習することによって、複雑な環境で適応的に制御できる制御方策が学習させる。

ショベルの制御方策には、Long short-term memory (以下、LSTM)¹³⁾ というネットワーク構造をベースにした NN を用いている。LSTM は時系列性を考慮する必要がある問題設定において、高い性能をあげたことが報告されている。操作量と各関節の動作速度の関係をモデリングし、レバー操作量を出力する制御方策のモデルとしても有効であった。LSTM の入力とは過去複数ステップの、状態とレバー操作量の系列で、出力は今のステップの最適なレバー操作量である。

強化学習アルゴリズムには、学習の安定性が比較的高い、Trust Region Policy Optimization¹⁴⁾ を用いている。学習に要する試行回数はおよそ 100 万回程度であり、1～2 日で計算が完了する。報酬関数は、土が



図—3 強化学習の報酬曲線のプロット図 (横軸はタイムステップ、縦軸は報酬値)

あると仮定している空間の通過面積をベースにしており、これによって土をたくさん掘るような制御方策が学習される。訓練時の獲得報酬曲線を図—3 に示す。

4. ショベルの無人自動制御システムの評価

(1) 状態認識システムの評価実験

初見の画像に対する推定精度を検証することで、本システムで利用している CNN が画像から状態を推定できているかを定量的に評価する。

画像データ 91,244 件 (26 日分) を日付ごとに分割し、2 日分のデータ (52,601 件) を検証用データ、それ以外の 24 日分のデータ (859,842 件) を学習用データに分ける。CNN を学習用データで学習させ、検証用データに対して状態推定した結果を示す。学習データ、正解データともに人手の関節点ラベルづけと AR マーカーによる角度推定によってデータを作成している。角度ごとに正解値と推論値の誤差の絶対値の平均を表—1 に示す。

ブームと水平線、ブームとアームの間の角度は 1～2° 程度の誤差で推定することができている。見たことのない新しい画像においてもある程度の精度で推定できていることがわかる。

アームとバケットについては他の関節角度に比べて推定精度が悪くなっており、画面で表示されるうちのバケットの割合が小さい、大部分が土の中にある場合に画像のみからでは判断が難しい場合があるといったことが課題として考えられる。

(2) 制御システムの評価実験

強化学習が、複雑に変化する環境において適応的に制御方策を変化することができているかを検証する。

表一 状態認識システムの認識精度の表 (単位は°)

| | ブームと水平線 | ブームとアーム | アームとバケット |
|------|---------|---------|----------|
| 角度誤差 | 1.0865 | 2.6202 | 9.4512 |


検証に用いた作業内容は、機体が地面に水平に設置されている条件下での、掘削作業である。

比較手法に教師あり学習で学習した方策を用いる。実際の熟練オペレータの掘削データを収集し、それらに対し深層学習を用いた教師あり学習をすることで獲得した掘削制御方策を用いる。訓練には 947 回分の掘削の操作ログ（油圧ショベルの各関節角度とレバー操作の時系列データ）を用いている。方策のネットワークに多層の全結合 NN を用いており、誤差関数にはレバー操作量の平均二乗誤差を用いている。

油圧ショベルの掘削を、深層強化学習で訓練させた制御方策で行った時の様子と、教師あり学習で学習させた制御方策で行った時の様子を、それぞれ写真—3、4 に示す。強化学習で学習させた制御方策は、土

をたくさん掘れていることがわかる。一方で、教師あり学習の制御方策で掘削されている土の量は少なく、また、動きのメリハリが強化学習の制御方策に比べてないことが定性的にも観測された。

教師あり学習では、掘削されている土の量が少ない理由として、オペレータが掘削を行った時の土と、実際に自動掘削をする時の土が同じでないことがあげられる。また、動きのメリハリについては、教師あり学習では状態に対応するレバー操作量の誤差を最小化するように学習するため、教師あり学習をした方策は、試行中の環境についてモデリングできず、適応的な制御ができない。その一方で、強化学習で学習した方策は教師あり学習に比べて複雑な環境をモデリングして適応的に制御できていることが確認できる。



写真—3 強化学習で学習した方策を用いて掘削した様子



写真—4 教師あり学習で学習した方策を用いて掘削した様子

5. おわりに

ここまで、深層学習を用いたショベルの無人自動制御システムについて述べた。本システムは無人の自動制御ができ、安価なセンサーのみを利用し、既存の重機に搭載できる機材のみからなるシステムであるため、建設現場の生産性向上に貢献できる。既存の技術では難しかったショベルの状態認識と自動制御が深層学習によってある程度できることを見た。最後に、自動制御システムの今後の開発方向性について述べる。

今後、本システムが現場に導入され、さらに生産性向上に貢献できるようになるためには、以下の2つの要素が必要になると考えている。

まず1つは、環境情報を活用した作業ができるようになることである。本稿では、機体が、地面と水平にある条件下での掘削を行うために制御機構について述べた。実際の現場では、機体の周りの土の形状や、他の重機などの周囲の環境は複雑である。これらの環境情報を把握して作業できるようになると、作業できる内容と条件が多様になる。ショベル自動制御システムがより広い条件で多様な動きができるようになると、運転員は他の仕事をできるようになり、建設現場の生産性が向上すると考えられる。

次に、制御精度の向上である。4.1節で示したように、現在の自動制御システムは依然として認識精度には誤差があり、数cm精度の制御はできていない。制御誤差が小さくなると、作業後の測量といった計測作業が合理化されるため、さらに建設現場の作業効率化に貢献できると考えられる。



《参考文献》

- 1) 「建設産業の現状と課題」, 国土交通省, 2017, <https://www.mlit.go.jp/common/0011495961.pdf>

- 2) 「職業別一般職業紹介状況 [実数] (常用 (含パート))」, 厚生労働省, 2018年11月, <https://www.mhlw.go.jp/content/11602000/G35-30103.pdf>
- 3) 「ICT建設機械施工による施工について」, 国土交通省, 2017年8月, http://www.ktr.mlit.go.jp/ktr_content/content/000654178.pdf
- 4) 「ImageNet Classification with Deep Convolutional Neural Network」, Alex Krizhevsky et al., 2012, <http://papers.nips.cc/paper/4824-imagenet-classification-with-deep-convolutional-neural-network>
- 5) 「Neural machine translation by jointly learning to align and translate」, Bahdanau et al., 2014, <https://arxiv.org/pdf/1409.0473.pdf>
- 6) 「Guided policy search」, Levine Sergey et al., 2013, <http://proceedings.mlr.press/v28/levine13.pdf>
- 7) 「YOLOv3: An Incremental Improvement」, Joseph Redmon et al., 2018, <https://arxiv.org/pdf/1804.02767>
- 8) 「Mask R-CNN」, Kaiming He, et al., 2017, <https://arxiv.org/pdf/1703.06870.pdf>
- 9) 「Reinforcement learning: An introduction」, Richard S. Sutton et al., 2014, <https://web.stanford.edu/class/psych209/Readings/SuttonBartoIPRLBook2ndEd.pdf>
- 10) 「Mastering the game of Go with deep neural networks and tree search」, Silver David et al., 2016, <https://www.nature.com/articles/nature16961>
- 11) 「Learning Dexterous In-Hand Manipulation」, OpenAI et al., 2018, <https://arxiv.org/pdf/1808.00177.pdf>
- 12) 「Dilated residual networks」, F. Yu, V. Koltun et al., In IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017, <https://arxiv.org/abs/1705.09914>
- 13) 「Long short-term memory」, Sepp Hochreiter et al., 1997, Neural computation, 9 (8) : 1735-1780.
- 14) 「Trust Region Policy Optimization」, John Schulman et al., 2015, <http://proceedings.mlr.press/v37/schulman15.pdf>

【筆者紹介】

西村 弘平 (にしむら こうへい)
 (株) DeepX
 エンジニア



富山 翔司 (とやま じょうじ)
 (株) DeepX
 エンジニア

