

# 自動走行を用いた人工知能導入教育プログラムの開発

本 池 巧

## 1. はじめに

### 数理・データサイエンス・AI 教育の広がり背景

昨今の大学生は、小さい頃からスマートフォンや SNS などに慣れ親しんでいるためか、システムエンジニアやプログラマ等の IT 関連職の人気の以前に比べると高まっている [1]。それにも増して IT 人材不足は深刻化しており、2019 年の調査報告 [2] によると、求職者との需要ギャップは、2025 年に 36 万人、2030 年には 45 万人と試算されており、特にその中で先端的 IT 人材と呼ばれる、データサイエンスや人工知能 (AI) 関連の人材不足が深刻化している。これに対処すべく、政府は 2018 年ごろから人材育成・確保に取組を進め、文部科学省では、2020 年度から、小学校→中学校→高校へと段階的にプログラミング教育等を推進するとともに、高等教育での「数理・データサイエンス・AI 教育プログラム認定制度 (リテラシーレベル)」の開設などに取り組んでいる。

人材不足に加えて ICT の導入が諸外国に比べて遅れていることも懸念されており、これに対処すべく 2021 年 9 月にデジタル庁を設置するなど国を挙げて取組んでいる。「デジタル時代の人材政策に関する検討会」で「我が国では、欧米等と比較して、IT 人材が IT 関連企業に従事する割合が高く、ユーザー企業に従事する割合が低い」と指摘されているように [3]、多くの企業で ICT を用いて客観的かつ体系的な意思決定が浸透せず、その結果、社内で ICT を戦略的に活用できる人材を採用せずに、ソフトウェアを外注することが一般的となる。この結果、社内での ICT 導入が思うように進まなくなっているといえる [4]。

このような人材不足と外注中心のシステム構築によって、ICT 専門人材が適切な部署に配置されないという結果につながった。それを反映して、現在での企業の ICT の利活用は、オンプレミスサーバで運用していたサービスのクラウド化やビジネスチャットなどによるコミュニケーションの転換など比較的外注で対応しやすいものに限られ、ビッグデータを活用するためには必須である IoT (Internet of Things) や AI、高度な自動化を実現するためのロボットなど導入については多くの企業が検討中か未検討の状況である [5]。社会全体で ICT の利活用に取り組んでいるが、思うように進んでいない理由は、表面的には、オフィススイートなどを使った定型的な業務プロセスの効率化の対処で、根幹の専門分野での課題解決等にデータサイエンスや AI の利活用が進んでいないためである。

さて、最近の AI 導入状況に目を向けると、大企業を中心に AI の導入事例が増えつつあるが、まだ人間の知的処理の一部分を担い、ある特定の作業だけを担当するいわゆる弱い AI の段階にとどまっている。人間と同様に考えて行動し、人間のように過去の経験に基づいて学習することで想定外の状況に対処することが可能ないわゆる強い AI の実現はまだまだ時間がかかると思われる。しかし、弱い AI のレベルではあっても、この数年その実力を大きく伸ばしつつあり、現場の導入意欲は高まっている。それに答えるように、最近では、AutoML のように AI 構築のプロセスを自動化するシステムの開発が進み、AI 開発に関する専門的な知識を持つエンジニアがいなくとも構築を可能とする、ノーコード (プログラミングの知識ゼロで開発できる) やローコード (簡単なプログラミング知識のみで開発できる)

の開発環境の普及が進んでいる。また、ONNX (Open Neural Network Exchange) のように作成した学習モデルを様々な環境で利用可能にする標準化の取組みも進みつつある。このように、現在では、AI の性能向上だけでなく、導入しやすくする環境の整備にも力が注がれ、今や AI の導入にあたっては、AI に関する専門知識よりもそれを適応する分野への専門知識の方に重心が移りつつあると言える。

## 大学教育の現状

上述の「数理・データサイエンス・AI 教育プログラム認定制度 (リテラシーレベル)」として認定されたプログラムは、多くは従来の情報リテラシーを発展させたものに数学・統計・プログラミングの要素などを加えたものが多く、幅広くデータサイエンス、AI の基礎知識を修得することができるものとなっている。しかし、上述するように、データサイエンスや AI を活用するためには、対象とする分野に関する専門知識が必要であり、この制度では、AI 人材不足への対応は充分とはいえず、上位レベルの教育プログラムの設定を急ぐ必要がある。

一方で、社会人—特に ICT 関連に従事する人—では、新しい技術にキャッチアップしなければ生き残れないという意識が広まりつつある。この分野は、情報を互いに共有する意識が高く、facebook などの SNS を通じた情報交換、企業による slack などを使った積極的なオンラインコミュニティ支援などによって、誰でも最先端技術に関する情報を入手可能になっている。さらに、先端技術の有識者によるセミナーやワークショップなどの情報発信から参加登録など開催支援 (資料配付など) を支援する connpass などのサービスが行き渡っている。学ぶ側からすれば気軽に勉強会に参加し、異業種間での情報交換などもでき、専門家を中心とするコミュニティに参加することができる。開催する側も気軽にセミナー等を開催し、集客できるようになっている。実施形態も、セミナーだけでなく、数日にわたって開催されるハッカソンなど多彩である。また、Coursera や edX など海外のオンライン学習サービスでは、バッジ、ナノディグリーといったマイクロクレデンシャルの利用も進みつつあり、スキルの可視化も進んでいる。このような環境下で、先端 IT 的な業務の従事者は、業務時間外に積極的にスキルアップに取り組んでいることが報告されている [3]。まだ分野は限定されてはいるが、ICT を最大限に活用した社会人向けの充実した学びの環境が急速に整備されつつある。他方、大学をはじめとする教育機関での ICT 活用した学習支援は大きく遅れをとっていると言わざるを得ない。実際、先端技術修得に意欲的な学生は、大学ではなくオンラインコミュニティで学びを選択する事例が徐々に増えている。

上述認定制度 (リテラシーレベル) の上位プログラムを実現する際、従来の教室での授業などではなく、すでに実社会で成果が出ている IT 先端人材が利用している学習環境、すなわち SNS の活用・クラウドサービスを使った学習・ハッカソンなど協同学習などを使うとより高い効果が予想される。本研究は、このようなモチベーションのもと、AI の社会実装として注目されている技術の一つである自動車の自動運転を具体的なテーマとして、物体認識など実務レベルの深層学習の知識・技能が修得できる教材の作成を目指す。

## RC カーの自動走行を教材とする理由

現在は、AI 研究は第 3 次ブームの中にあるといえる。過去の二回のブームを通じ、人手のみで人間と同等な知的処理を行える機械を構築することは難しいことが結論された。今では、機械自身に学習させることで知的処理能力の獲得を目指す機械学習が主な AI 開発の主な手法となっている。すなわち、人間があらかじめ推論・判断のルールを機械に与えるのではなく、機械自身が与えられたデータなどからルールを作り出す方法である。2010 年代以前は、着目すべき特徴量などを人間が設計した後に機械

学習を実行してきたが、今では、特徴量の抽出を含めて一体して学習する深層学習へと発展している。

今回、構築する教材は、深層学習の基本について学ぶことを目指しているが、その観点で、無線操縦モデルカー（RC カー）の自動走行が、画像認識、音声認識などの題材に比べて、以下の三つの理由から教材として相応しいと判断する：

- 1) 課題が分かりやすい：AI を実践的に活用するには個々の課題について専門的な知識が必要である。RC カーを既定のコースに沿って操縦するという問題は、どのような専門性を持った学習者にとってもわかりやすく、作成した AI の性能もわかりやすい。また、シンプルな課題であるが、「より短い時間でコースを周回する」、「コースアウトを少なくする」、「コース上の障害物を避ける」など、学習者自身で、達成目標を様々な形にアレンジして拡張することができる。
- 2) 学習データが容易に収集可能：深層学習を行うためには、大量のデータが必要である。深層学習を使った教材を作成する際、実はデータの確保が問題となる。講義の中に、あらかじめデータを用意した例題として取り組ませることは容易である。しかし、ハッカソン形式で実施する場合、学習者自身がデータを用意しなければならず、単調作業な収集作業が長時間つづくため学習意欲が下がるなどの課題がある。しかし、自動走行であれば、ゲーム感覚で RC カーを操縦するだけで、必要なデータが短時間に用意することが出来る（RC カーの設定や走行コース形状にもよるが、一万件のデータを 10～15 分で収集可能）。
- 3) コスト、入手性など運用面のメリット：自動走行 RC カーキットのなかで一般の市販の RC カーに、SBC、サーボモーターコントローラ、組み込みカメラなど汎用品で構成可能されたオープンソースのものを使うことで、安価に教材を調達できるだけでなく、ハッカソンでの実施において重要な補修部品の確保、教材のバージョンアップなども行いやすい。

本論文では、実践的な AI の活用をワークショップ形式で学ぶ教育プログラムを実施した結果を報告する。なお、ワークショップ形式で実施する関係で、時間割の問題、さらに教室の設備などの問題もあり、試験的な運用は大学ではなく、飯能市内の中学校の協力を得て実施した<sup>1)</sup>。

## 2.RC カーの自動運転を使った自動走行

### 自動車の自動運転

自動運転は、AI の大規模な社会実装の一つとして現在精力的に研究・開発が進められている。自動運転は、運転の主体、走行対象領域などによって以下に示すレベル 0 からレベル 5 の 6 段階に分類されている [6, 7]。

表 1: 自動運転のレベル

レベル	名称	自動運転の概要	操作の主体
0	運転自動化なし	搭乗者がすべての運転操作を実行する。	搭乗者
1	運転支援	特定の状況において、自動化システムがステアリング操作または加減速・停止のいずれかの操作を行い、残りは搭乗者が操作する。それ以外の状況では、搭乗者が操作する。	搭乗者

2	部分運転自動化	特定の状況において、自動化システムがステアリング操作と加減速・停止の操作を行う。それ以外の場所では、搭乗者が操作する。その際、周囲の状況の検知などは搭乗者が行う。	搭乗者
3	条件付き運転自動化	特定の状況において、自動化システムがすべての運転に関する操作を行う。自動運転中、自動操作が難しい場合は、システムが搭乗者に代わりの運転操作を要請する。	システム
4	高度運転自動化	特定の状況において、自動化システムがすべての運転に関する操作を行う。自動操作が難しい場合の対応もシステムが担い、その際、搭乗者は運転操作をしない。	システム
5	完全運転自動化	あらゆる状況において、自動化システムがすべての運転に関する操作を行う。	システム

自動走行に関する研究は、1990年代から進められてきた、2000年代、米国国防高等研究計画局（DARPA）による自動運転コンテスト（「DARPA Grand Challenge」、「DARPA Urban Challenge」）をきっかけに、自動走行の研究が広がりを見せた。2010年代になると、カメラ・測距センサーなど走行に必要なセンサーの性能の向上と深層学習による画像認識能力の飛躍的な進歩によって、現在では、自動車メーカーによる自動運転はレベル3相当の自動化が実現されている。現在、レベル5の実現を目指して各国で実証実験が重ねられており、我が国では、今後数年を目途に、レベル4の自動走行の実用化に向け、高速道路での高度な自動運転の市場化および限定地域における無人自動運転移動サービスの実現（2020年目途）、高速道路における完全自動運転の市場化（2025年目途）などを進めている。

## 深層学習と自動走行

現在のAIの開発では、機械に大量のデータを与え、機械が自ら推論などのルールを習得する機械学習が用いられる。機械学習は大まかには以下の三つに分類される：

- 1) 教師あり学習：学習用のデータ（教師データという）とそのデータに対する答えを与え、入力データから答えを導き出すルールを機械が作り出す手法。例えば、画像認識など分類や商品購入の予想など、データを使った予想や分類に用いられる。
- 2) 教師なし学習：データの中から、そこに内在する構造や関係性を見出す手法。ECサイトでのレコメンデーションや異常値検出などに用いられる。
- 3) 強化学習：エージェント（Agent）と呼ばれる機械が環境の状態を観察し、観察結果に基づいて行動した結果、何らかの報酬が得られる仕組みを用意し、より多くの報酬を受け取るように、エージェントがとるべき行動を学習する手法。前の二つの手法が実際のデータを使うのに対して、機械を含む環境（実物またはシミュレーション）を用意する。


この他に、ある領域で学習したものをベースに別の領域で学習することで効率的に学習を進める教師あり学習の一種の転移学習や、強化学習の中で、人間など他者の行動を模倣する模倣学習などもある。

各手法の実装方法にも様々なものがあるが、その中で人間の神経回路網の特徴を数学的にモデル化したニューラルネットワークがよく用いられる。ニューラルネットワークとは図1に示すように、神経細胞の振る舞いを数学的にモデル化した人工ニューロンを入力層、隠れ層、出力層に束ね、各層のニューロンを結合したものである。なお全体が4層以上あるものをディープニューラルネットワーク（Deep



Neural Network: DNN) と呼ぶ。

図 1: ニューラルネットワーク



DNN は、インターネット普及によって学習に必要大規模データが整ったことと、誤差逆伝播法やオートエンコーダなどの技術革新によって着目する特徴量までを含めて自動で学習できるようになったことで、多方面において実用的な性能が実現されるようになった。さらに、画像認識用途に、ディープニューラルネットワークに画像処理で用いられる畳み込み処理を行う層を加えた畳み込みニューラルネットワーク (Convolutional Neural Network: CNN) [8] や、時系列データを扱えるように、過去の隠れ層のデータを取り込めるように拡張したリカレントニューラルネットワーク (Recurrent Neural Network: RNN) [9] など、特定分野に適合した DNN モデルなどがある。

レベル 4 またはレベル 5 の自動走行を実現するためには、高精度のセンサ・高解像度のカメラとそこから得られるデータを的確に分析・推論する AI を必要とする。画像認識の分野で高い性能を示す CNN を導入することで、今まで人間の手作業で調整していた画像の特徴抽出を含めて機械が学習可能となり、物体認識、車道検出、経路プランニング、ステアリング操作を何段階に分かれた処理が、カメラの画像データから直接ステアリング操作を学習<sup>2</sup>することが可能となった [10]。

### SBC を使った自律走行学習キット

フィジカルコンピューティングから始まった Makers ムーブメントによって、Arduino に代表されるワンボードマイクロコンピュータは、マイコン工作程度の用途から市販電子機器への組み込みまで進化した。ワンボードマイクロコンピュータは、16bit MPU が中心で、利用できるメモリが少なく深層学習を使った推論を実行することはできなかった。2010 年代になると、Linux など本格的な OS を利用できる 32bit MPU 搭載のシングルボードコンピュータ (SBC) が安価に入手可能となった。このような SBC は、PC に匹敵する演算能力・記憶容量・ネットワーク機能を有しており、AI を使った画像認識などの推論をリアルタイムで実行するだけでなく、深層学習専用のハードウェアを組み込むことで、深層学習そのものを実行することも可能である。高性能 SBC の出現によって、利用現場において深層学習と推論を実行するエッジ AI が実現されている。

自動車の自動走行は、複数の車載カメラ、レーダー、レーザ測距など多数のセンサを使った複雑なシステムであるが、道路を認識してそれに沿って走行する基本的な動作を、三つのカメラ画像を使った深層学習 (CNN) で実現できることが実証されたことで [10]、Amazon、NVIDIA 社や自動走行コミュニティなどから、車載カメラ一基と SBC 一枚で構成された深層学習による自動走行 RC カーキット (図 2) が提供され、自動走行を教材とするワークショップや自動走行 RC カーレースが盛んに開催されるようになり、自動走行の技術普及にむけた活動が活発化している。

図 2: 自動走行学習用キット



図 2 に紹介した代表的な三つキットの特徴を表 2 にまとめる。各キットが採用する機械学習は、DonkeyCar が教師あり学習、JetRacer が転移学習、DeepRacer が強化学習となっている。DonkeyCar は、CNN ベースの深層学習による end-to-end の自動走行を実現している。人間が RC カーを操縦することで教師データを作成する方法は、教師データ生成プロセスがわかりやすいことと、学習後のモデルの推論に操縦者の癖が反映されるなど、AI に初めて触れる者にとって、深層学習の工程の全容がわかりやすいものになっている。その反面、他のキットに比べて多くのデータを必要とする。他の二つのメーカー製のキットは、転移学習や強化学習など最新の AI の手法を取り入れ、少ないデータやシミュレータで学習できるように工夫されており、簡単に精度の高い自動走行を実現することで、より複雑な自動走行の問題に取り組むことが出来るようになっている。ただし、車体の構造などハードウェアが事前にチューニングされているため、RC カーの選択の幅は狭い。まとめると、ソフトウェアの開発経験がない初心者には、システム全体の構成が簡素で自動走行システム構築までのプロセスがわかりやすい DonkeyCar が適しており、ソフトウェア等の開発経験のあるエンジニアが、自動走行をテーマに AI を使った実践的な課題解決に取り組む場合は、JetRacer や DeepRacer が適していると思われる。なお、初心者の場合、誤操作などによる車体の破損が多くなると想定されるが、汎用パーツで構成される DonkeyCar は予備パーツを用意しやすく、ワークショップ実施中の様々なトラブルに対応できる体制を整えることができる。この点でも初心者向きと言える。

表 2: 代表的な三つのキットの特徴


名称	DonkeyCar	JetRacer	DeepRacer
深層学習方法	教師あり学習	転移学習	強化学習
SBC	Raspberry Pi 3B, 4B, JetsonNano	Jetson Nano	独自設計
トレーニング	PC、サーバ	オンボード	クラウド上のシミュレータ
学習データ数	5,000～20,000	200～500	—
データ作成方法	人によるマニュアル走行	アプリを使った	シミュレータ
対応 RC カー	多数	タミヤ TT02、Latrax Rally	独自設計

### 3. AI による自動走行学習プログラムの構成

#### 3.1 RC カーの自動走行の仕組み

RC カー単体の動作の仕組みを図 3(a) にしめす。通称プロポと呼ばれる送信機を使いレバーなどの操作量を電波で送信する。受信機はプロポから受け取った電波を解読し、スロットル操作であれば ESC (Electronic Speed Controller) で駆動モータの出力を制御し、ステアリング操作であればサーボモータを使って車輪の向きを変える。受信機が使うスロットルおよびステアリング制御に使われる信号は、特殊な製品以外はほとんど規格化された PWM (Pulse Width Modulation) 信号であるので、AI を使った自動走行では、SBC にサーボモータコントローラなど PWM 信号を発信するハードウェアを追加することで、受信機に代わって ESC およびサーボモータを制御する (図 3(b))。

図 3：通常の RC カーと自動走行用に SBC を組み込んだ RC カーの制御方法



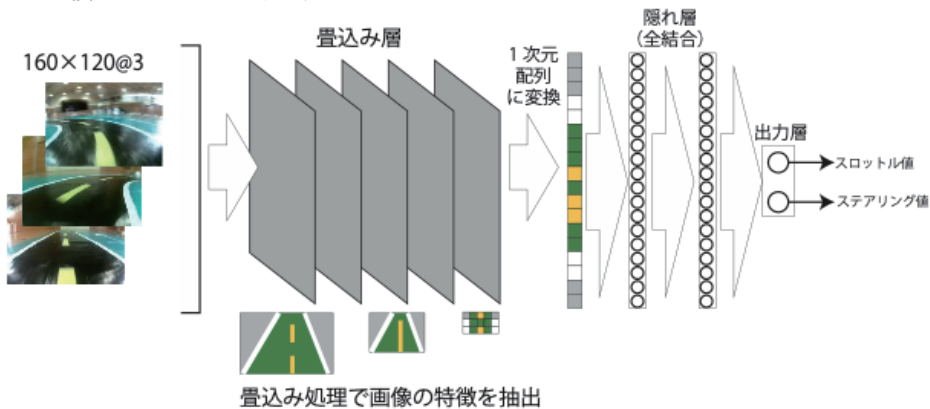
AI を使った自動走行の原理は、いずれのキットでもほとんど同じで、SBC に搭載された推論モデルが、組み込まれたカメラの画像からスロットルおよびステアリング制御のための数値を推論し、その値を使って RC カーを制御する。推論モデルの構築方法はそれぞれ異なるが、今回採用している DonkeyCar には、SBC に接続したワイヤレスジョイスティックを使って人間が運転したデータを記録するマニュアルモードと DNN 推論モデルを使ってカメラ画像からスロットルとステアリング操作を推論して運転する推論モードの二つのモードがある。

#### 教師あり学習による自動走行

DonkeyCar では、車体前面に設置したカメラの画像 (160×120 ピクセル、24bit カラー) から、ステアリングとスロットル操作レバーの二つの値を推論するモデルが使用される。深層学習を行う前に、まず、人間がマニュアルモードで運転し、カメラ画像・ステアリング値・スロットル値をセットとする教師データを SBC 内部に保存する。経験則として、安定した自動走行が可能な AI を構築するためには、教師データは 5000 個以上必要とするが、それは、自動走行トラックを 10 周程度の周回によって得られる。なお、データ収集はスロットルの値から速度を推定し、移動速度に応じて収集間隔を調整している。収集したデータを使った学習は、高い演算能力を持つ PC またはサーバで行う。今回は、利用時間に制限があるが GPU を使った高速並列計算が可能な Google Colaboratory サービスを利用した。学習結果として得られた推論モデルを SBC に組み込み、推論モードで制御プログラムを実行することで、RC カーは走行トラックを自動走行する。参考のために、使用した CNN の概要を図 4 に示す。160×120×3 の画像データを、サイズ 5×5 のカーネルを使った 3 段の畳込み処理、サイズ 3×3 のカーネルを使った 2 段の畳込み処理で画像の特徴を抽出し、全結合の隠れ層 2 層の DNN を経てニューロン 2 個でスロット

ルとステアリングを出力する。

図4：使用した CNN の概要




### 3.2 学習環境の構成

#### 自動走行用ネットワーク環境

RCカーに組込んだSBCには、消費電力を抑えるために入出力デバイスは接続されていないため、RCカーの制御は、ノートPCからWi-Fi経由でSBCにログインして行う。学校内の基幹ネットワークとつながっているWi-Fiには厳重なセキュリティ設定が施されている場合が多い。一方、SBCは比較的セキュリティの緩いWi-Fiでの運用を想定しており、WPA2エンタプライズ認証への未対応、プライバシーセパレーター機能によってPCからSBCへのアクセス遮断などトラブルが発生する可能性が高い。そこで自動走行用にプライベートLANを構築することで、SBCとPCの安定的な接続を確保する（図5）。なお、複数の教室・会場にまたがって実施することを想定し、Mesh Wi-Fiを用いてLANを構築した。教師あり学習を実行する際は、制御用PCを使ってSBCからデータを吸い上げ、USBメモリなどを使ってそれをインターネットに接続するPCへデータを移す。そのPCを使ってGoogle Colaboratoryを用いて教師あり学習を実施し推論モデルを作成する。最後に、逆のルートでできあがった推論モデルをSBCに組み込む。

図5：自動走行実施のためのネットワーク環境



#### 深層学習システムのカスタマイズ

DonkeyCar本体の操作は、セキュアシェル（SSH）経由で、RCカー上のSBCにログインした後にキー



ボードからコマンドを入力することになる。DonkeyCar のコマンド群は、キーボードを使ったコマンド操作に慣れた者にとってはそれほど難しいものではないが、初心者にとっては、カレントディレクトリなど慣れない概念もあるため、自動走行とは関連性の低い作業は、独自に作成したユーティリティコマンドで隠蔽化し、本質的な作業に集中できる環境を構築した。

### 3.3 ワークショップの構成

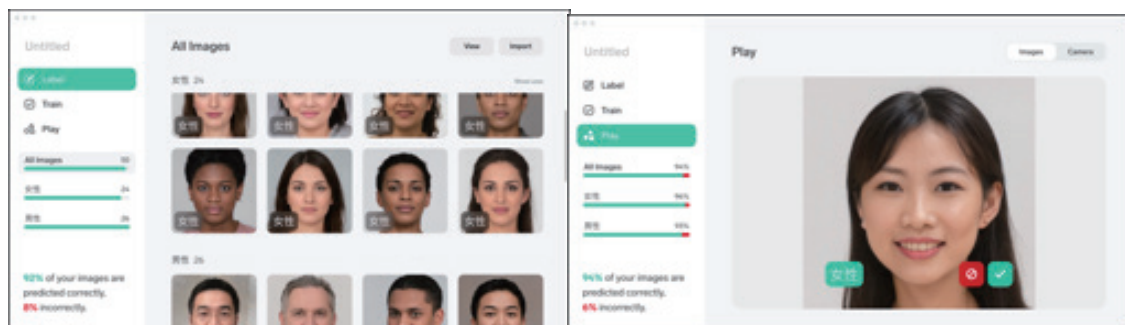
以上の説明した AI による RC カー自動走行の教育プログラムを、実際に飯能市立南高麗中学校 2 年生 8 名を対象とし二日間のワークショップとして実施した結果について報告する。

#### 1 日目：2 時間程度で以下の二つの内容に取り組む

##### 1-1) 教師あり学習について仕組みを学ぶ：

中学 2 年では、深層学習について理論から理解することは難しいため、AI に関する簡単な解説をした後、教師あり学習とはどのようなものかを簡単に体験し理解することとした。具体的には、Microsoft 社が開発中のノーコードで AI を構築できるアプリケーション「Lobe」を用いて写真から男女の性別を判別する AI の構築に取り組んだ（図 5）<sup>3</sup>。教師データとして AI による人間の顔の画像生成サービス Generated Photos で生成された画像を使い、テストデータとして同じサービスの別の写真や PC 内蔵カメラで移した自分の顔で男女の判定に取り組んだ。

図 6: Lobe を使った教師あり学習



(a) トレーニング画面

(b) AI の検証画面

##### 1-2) RC カーのチューニングと運転操作の練習：

教師あり学習において AI の性能は、教師データによって決まるといっても過言ではない。DonkeyCar の場合、人間が操縦したデータが教師データとなるため、生徒はある程度 RC カーの操作に習熟しなければならないため。まずは、RC カーのスロットルとステアリングの調整を行う。RC カーの操作は、ジョイスティックを使うが、スティックの入力値と、実際の ESC およびサーボモータに送る値を調整する。スロットルは、RC カーの操作性に直結するため、大きい値だと、最高速度は大きくなる反面、加減速の制御が難しくなるため、生徒は自分の技量に応じて運転しながら調整を行う。

#### 2 日目：約 3 時間程度で以下の二つの内容に取り組む

##### 2-1) 1 回目の教師データの作成

有効な教師あり学習を実行するために必要な 5000 個以上の走行データは走行トラックを 10 周程度周回することで得られる。10 周程度周回できるようになったところで、教師用データの収集に

取り組んだ。なお、初回は、特に運転についてのアドバイスなどは行わず、自由に走行させた。

## 2-2) 推論モデルの構築

RC カーから走行データ取り出し、それを Google Colaboratory 上に用意した深層学習環境に読み込ませ、できあがった推論モデルを RC カーに組み込む。この一連の作業は、自動走行とは関係の無いファイル転送コマンドなどがほとんどであるため、今回は生徒でなく実施スタッフにて行った。DonkeyCar では、機械学習のアルゴリズムの選択など細かく調整することもできるが、そのためには機械学習の詳細を理解しなければならないため、今回のワークショップではデフォルトの図4のCNNを用いた。

## 2-3) 推論モデルによる自動走行と評価

推論モデルをRCカーに組み込み、モデルを使った制御プログラムをSBCで実行する。自動走行は、ブラウザを使って操作する。カメラの画像と推論モデルによるスロットルとステアリングの値がリアルタイムで表示され、AIがどのような推論を行っているかを確認することができる。

図7: RCカーの自動走行



1 回目は、教師用データ収集に際して何もアドバイスをしなかったため、うまく周回できる生徒もいればうまくいかない生徒もいた。全員の自動走行が終わったところで、各自の自動走行の内容を評価し、自動走行はうまくできたか（トラックから外れて戻れなくなるなどはなかったか）、あればそれを解決するにはどうすればいいかなどを議論させた。

## 2-4) 2回目の教師データの作成と自動走行

1回目の自動走行の結果の課題を踏まえ、教師データの生成→推論モデルの作成→自動走行を行った。自動走行は、生徒二人ペアで実施したが、ペアによっては、二人の間で操縦技術にばらつきがあり、1回目の課題を2回目ですぐ克服できない場合もあった。

## 4. まとめ

CNNを使ったRCカーの自動走行を通じてAIを学ぶ教育プログラムの試験的な実施を、中学2年生対象に試験的实施を行った。二日間合計約5時間のワークショップで、AIに関する知識ゼロから初めて、コースアウトすると復帰できないなど不完全なケースもあったが、参加者全員が、教師データを作成し、

RC カーを自動でコーストラックを周回させることができた。深層学習においては大量の質のよい教師データの手配が鍵となるといえるが、今回の取組では、参加者が深層学習の核心部分について学習できたといえる。初回の取組で失敗せずに走行させることができたことは参加者に高い満足度を与え、さらなる課題への動機付けにもなると思われる。

単調作業になりがちな教師データ作成<sup>4</sup>をゲーム感覚で楽しめるものにしたことと、CNN で作成した推論モデルの精度が高いことが、このような結果につながったといえる。自動走行を教材としたもう一つの長所として、教師データが可視化されており、データの質の判断が明確である点が挙げられる。教師が特に説明せずとも、よいデータとはコースアウトが少なく、スムーズにカーブを曲がるものということが自然に理解され、無意識になるべくそれに近づくようにデータを作成するようになる。さらに、できあがった AI の推論も、教師データと同様に可視化できており、推論モデルの精度や問題点などの把握が容易である。自動走行の成功率が高いことから、初学者が深層学習に取り組む際には、入力（教師データ）と出力（推論モデル）がともに可視化されていることが重要ではないかと思われる。可視化はできあがった推論モデルの改善にも役に立つ。今回は実施できなかったが、自動走行時にあるカーブでコースアウトをするようであれば、自分でそのカーブの付近を走らせ、コースアウトの原因がなにかを考え、教師データの改善に取り組める。

可視化の効果は、取組中の参加者の態度にも現れており、失敗なく自動で周回できても、それに満足することなく、よりうまく走行できるよう自ら考えて改良に取り組む様子が見て取れた。意図的に指導しなくとも、AI 構築において重要な評価・改良のプロセスの教育も実施できていると思われる。ただし、今回の教材に内在するゲームの要素は、本来の目的を忘れ、好き勝手に走らせてしまい、結果としてうまくデータ作成が出来ない参加者がいたことが反省点としてあげられ、楽しみながら学ぶということに集中するように誘導する必要性があるといえる。

中学生対象のワークショップでは、最速の RC カーの周回タイム約 30 秒、事前に大学生向けに行った際の結果が約 60 秒であった。ともに、RC カーの操作は初めてであったが、RC カーの運転の修得は、平均的には中学生の方が大学生よりも優れているかもしれない。中学生であっても、コース上に障害物の設置など難易度を上げた課題に取り組ませることが可能と思われる。同じ参加者を対象に、次の段階として、周回タイムの向上、走行トラック上に設置した障害物を避けるなど、難易度を上げた課題に取り組むワークショップの実施を検討したい。

DonkeyCar のフレームワークは自由度が高く、様々な RC カーなどにも適応可能である。今回は、安定した走行と搭載バッテリー容量の点で比較的大きい 1/12 サイズの RC カーとそれに合わせた走行トラック（5.36×8.20m）で実施した。そのため、通常サイズの教室には収まらず体育館で実施することとなった。今後は、一般的な教室で多くの参加者を集めて実施するために、RC カーのスケールダウンや小型大容量のバッテリーの採用などを検討しているところである。

## 謝辞

今回のワークショップ実施にあたり授業時間の調整など多方面にわたり協力していただいた飯能市立南高麗中学校の馬場治男校長先生および橘育郎教頭先生に感謝する。ワークショップ実施中の生徒のサポート、学習モデルの作成などサポートした藤村君に感謝する。

## 参考文献

- [1] 株式会社ディスコ, 「キャリアタス就活 2022 学生モニター調査結果」,  
[https://www.disc.co.jp/wp/wp-content/uploads/2021/01/202101\\_gakuseichosa\\_k.pdf](https://www.disc.co.jp/wp/wp-content/uploads/2021/01/202101_gakuseichosa_k.pdf), 2021
- [2] 経済産業省, 「IT 人材需給に関する調査 (概要)」,  
[https://www.meti.go.jp/policy/it\\_policy/jinzai/gaiyou.pdf](https://www.meti.go.jp/policy/it_policy/jinzai/gaiyou.pdf), 2019
- [3] 経済産業省, 「我が国における IT 人材の動向」,  
[https://www.meti.go.jp/shingikai/mono\\_info\\_service/digital\\_jinzai/pdf/001\\_s01\\_00.pdf](https://www.meti.go.jp/shingikai/mono_info_service/digital_jinzai/pdf/001_s01_00.pdf), 2021
- [4] 谷島 宣之, 「ソフトを他人に作らせる日本、自分で作る米国」, 日経 BP, 2013
- [5] 日本情報システム・ユーザー協会, 「企業 IT 動向調査 2020」,  
[https://juas.or.jp/cms/media/2020/05/it20\\_ppt.pdf](https://juas.or.jp/cms/media/2020/05/it20_ppt.pdf), 2020
- [6] Society of Automotive Engineers, “Taxonomy and Definitions of Terms Related to Automation Systems for On-Road Motor Vehicle”, [https://www.sae.org/standards/content/j3016\\_201609/](https://www.sae.org/standards/content/j3016_201609/), 2016
- [7] 自動車技術会, 「自動車用運転自動化システムのレベル分類および定義」,  
[https://www.jsae.or.jp/08std/data/DrivingAutomation/jaso\\_tp18004-18.pdf](https://www.jsae.or.jp/08std/data/DrivingAutomation/jaso_tp18004-18.pdf), 2018,
- [8] Y.LeCun, L.Bottou, Y.Bengio, and P.Haffner, “Gradient-Based Learning Applied to Document Recognition”, Proc. Of The IEEE, 1998
- [9] C. L. Giles, G. M. Kuhn, and R. J. Williams, “Dynamic recurrent neural networks: Theory and applications,” IEEE Trans. Neural Networks, vol. 5, 1994.
- [10] M.Bojarski, B.Firner, B.Flepp, L.Jackel, U.Muller, K. Zieba and D.D. Testa, “End-to-End Deep Learning for Self-Driving Cars”, <https://developer.nvidia.com/blog/deep-learning-self-driving-cars/>, 2016
- [11] DonkeyCar, <https://docs.donkeycar.com>
- [12] JetRacer, <https://github.com/NVIDIA-AI-IOT/jetracer>
- [13] DeepRacer, <https://aws.amazon.com/jp/deepracer/>

## 注

- <sup>1</sup> 中学校は、技術家庭科室、コンピュータ室、体育館といった総合的な学習施設が整っておりハッカソン形式の実践的な AI の教育を行う場としては理想的である。中学校はクラス単位で授業が進行するため、中学校側の協力があつてのことではあるが、時間的に柔軟な教育プログラムの実施が可能である。
- <sup>2</sup> エンドツーエンド (end-to-end) 深層学習と呼ぶ。
- <sup>3</sup> 厳密には Microsoft Lobe は転移学習を使っているため教師あり学習ではないが、データからルールを学ばせるとはどのようなものか理解するという目的の場合、少ないデータセットで有効な推論モデルの構築が可能な転移学習は有効な手段といえる。
- <sup>4</sup> 今回の参加者は、3000～5000 件の教師データを作成している。同じ 10 周でも、運転によってデータ数は異なり、運転の上手な参加者の教師データは総件数が多い傾向にあった。