

AI 応用研究所

報告書

令和 4 年 3 月 31 日

組込み Linux 機器用電源回路に関する一考察 ……1

情報ネットワーク工学科

千田 陽介

地域の美容業界を対象とした地域課題解決型 AI 教育プログラム ……6

の成果 ～顔照合受付およびヘアスタイル提案アプリの実装～

情報ネットワーク工学科

河野 央

対話型 AI 自動運転モビリティの社会実装に向けた人工知能システム ……10

の改良

インテリジェントモビリティ研究所
自動車システム工学専攻

東 大輔, 服部 雄紀
太田 遼介, 松永 周大

小さな例題から始めるニューラルネットワーク ……14

教育創造工学科

松浦 望

AI を用いた絨糸耳部の検出 ……20

機械システム学科

澁谷 秀雄

熱とエネルギーに係る ES と CFD の連成解析手法の開発 ……24

建築・設備工学科

山本 竜大

陸上競技における次世代風速計開発に向けた基礎的実測 ……26

建築・設備工学科
情報ネットワーク工学科
教育創造工学科

山本 竜大
千田 陽介
中嶋 康博

AI を用いた空調用エネルギー削減技術の検討 …29

AI 応用研究所	呉 濟元, 小田 まり子,
	新井 康平
情報ネットワーク工学科	千田 陽介
PC サポートセンター	八坂 亮祐

帯水層蓄熱システムの効率的な運転方法の検討 …32

AI 応用研究所	呉 濟元
----------	------

プログラミング学習を支援する画像診断 AI チャットボットの試作 …36

PC サポートセンター	八坂 亮祐
AI 応用研究所	小田 まり子, 呉 濟元

AI を活用したキュウリの栽培支援アプリケーションの開発 …40

PC サポートセンター	八坂 亮祐
AI 応用研究所	小田 まり子, 呉 濟元

組込み Linux 機器用電源回路に関する一考察

情報ネットワーク工学科 千田 陽介

令和4年3月

1. 研究の背景と目的及び期待される効果

現場で人工知能技術の検証実験を行うには、Raspberry PI や Jetson Nano といった組込み Linux ボードが便利である。しかしこれらのボードは Linux が動作しているためいきなり電源供給を絶ってはならず、きちんとシャットダウン手続きを踏まなければならない。これは毎日日中だけ運用するといった非 24 時間的な実験の障害となっている。

組込み Linux ボードでシャットダウンする方法は幾つかある。一番シンプルな方法はモニターやキーボードを付け、そこからログインしてシャットダウンコマンドを打つことである。しかし組込み Linux ボードにモニターやキーボードを付けることは組込み Linux ボードを使うメリットを失ってしまい本末転倒である。そこでネットワーク経由でログインしてシャットダウンコマンドを打つ方法がよく取られる。これは実現が簡単なものの、いざ運用する場合煩雑である。

単体で手軽にシャットダウンを実現する方法として図 1 のように本体にボタンを付けるやり方がある。システム起動時(例えば/etc/rc.local などから)、このボタンが取り付けられた GPIO を監視し必要に応じてシャットダウンを行うスクリプトを呼び出せばよい。経験上ボタンが押されたら即シャットダウンするように作ると誤動作が頻発し使いにくい。一定のタイミングで二回押すなどパターンを含めた方がよい。



図1 シャットダウンボタン

ところで組込み Linux ボードを使う実験はボード単体で行うことは少なく、ハブやルータ、照明、センサーといった様々な機器も同時に動かす。実験を終えるに当たって集中スイッチでこれらすべての機器の電源を同時に切ることができたら便利である。すなわち組込み Linux ボードにおいて電源の遮断を検出し、すみやかにシャットダウンを行う仕組みがあるとよい。この技術を確立することで、人工知能のフィールド実験がより手軽に行えるようになると思われる。

2. 電源回路の開発

電源の遮断を検出しすみやかにシャットダウンするためにはシャットダウン手続きが完了する数十秒間の電力が供給されなければならない。その概念を図2に示す。




図2 電源回路のブロック図

組込み Linux への電源(power)は AC アダプタからの電源と蓄電池(Bat.)からの電源の二系統があり、セレクトア(SW1)で選択される。このセレクトアは AC アダプタからの電源があればそちらを、そうでなければ蓄電池からの電源を選択する。AC アダプタ側の電源は組込み Linux で監視しており(in), 供給が絶たれるとすみやかにシャットダウンを行う。セレクトアは power の先が無負荷でもある程度の電力を消費する。組込み Linux が必要としていない時に蓄電池の電力を無駄に消費しないためスイッチ(SW2)を付ける。このスイッチの制御は組込み Linux から行う。組込み Linux はシャットダウン直前に出力(out)を Low にするが、そこからシャットダウンが完全に終わるまで若干のタイムラグがある。そこで SW2 への指令に遅れ要素を設けその時間を作っている。一方蓄電池は電源断からシャットダウンが完全に完了するまでの短い間の電力を供給する。毎回繰り返すと充電が無くなるため AC 電源が入っている間は充電を行う(charge)。以上の動作を実現する中核となるのは電源セレクトア(SW1)であるが、これには Analog Devices の LTC3118 を用いた。図3に Strawberry Linux の LTC3118 モジュールを用いた回路図を、図4に Raspberry PI を用いた試作システムの写真を示す。さらに図5にシステム起動時に呼び出す電源監視用 python スクリプトを示す。




図3 電源回路図




図4 試作回路と実験装置

```
#!/usr/bin/env python
import RPi.GPIO as GPIO
import os, time

GPIO.setmode(GPIO.BCM)

GPIO.setup(21, GPIO.IN)
GPIO.setup(16, GPIO.OUT)
GPIO.output(16, GPIO.HIGH)

cnt=0;
while 1:
    time.sleep(1)
    if GPIO.input(21)== 0:
        cnt += 1
    else:
        cnt=0
    if cnt > 5:
        GPIO.output(16, GPIO.LOW)
        os.system("sudo shutdown -h now")
```

図5シャットダウンスクリプト

スクリプトの A 部分で gpio16 を High にすると図 3 内の 22 μ F のコンデンサに電荷が溜まりこも High になる。これは二つのトランジスタ(Tr)を介して増幅され Pch FET(先述の SW2)を on にし LTC3118 の In2 側に電気を供給する。AC 電源が遮断されると In1 側の電圧が下がる。この変化は gpio21 を介してスクリプト B 部分で検出される。ノイズ対策のため 1 秒毎に 5 回連続で Low 検出すると同 C 部分で gpio16 を Low にすると同時にシステムのシャットダウンを行う。gpio16 と 22 μ F の間にダイオードがあるため電気が逆流することなく、コンデンサの電圧は High のままである。その後放電によって電圧が下がるまで FET は on 状態が続く。本回路の定数ではその時間はおよそ 50 秒であった。AC アダプタとニッケル水素電池の間にある 47 Ω の抵抗はトリクル充電用のものである。計算上では 70mA、約 0.04C が流れる。なお図 4 には電源回路の他に SSD と RTC が映っている。Raspberry PI のシステム(Raspbian)は本来 microSD で動く。しかし SD メディアは書き込み可能回数が少なく長時間運用するサーバのシステムを格納する用途には向いていない。SSD はその代わりとしたものである。また Raspberry PI は本来起動時に現時刻を NTP で外部から取得する。これは何時何が起きたかという記録に使うためにはネットワークに繋げる必要があることを意味する。RTC(Real Time Clock)モジュールは内部に時計を持ち、これを取り付けることでネットワークに繋がってなくても現時刻を得ることが出来る。いずれもこういった実験システムでは重要な要素であるが、本報の趣旨とずれるのでその存在の紹介だけに留める。

3. 実験結果

図 3 に示した回路が正しく動作するか確認するため図中④⑤部分の電圧をオシロスコープで観察した。図 6 は時刻 0 で AC アダプタの電源供給を絶ってみた時の様子である。この図における④の動きは今回用いた AC アダプタの特性であり全ての AC アダプタがこのように動くわけではないことに留意されたい。AC 供給が絶えても Raspberry PI への入力 5V は維持されており、正しくシャットダウンするまでの電力が確保されていることが見て取れる。実際設計通りシャットダウンできる。




図6 AC電源遮断時の供給電源の様子

しかし Raspberry PI の USB ポートに USB カメラを取り付け、画像取得・画像処理といった実践的な運用を行うと話は変わる。USB カメラが稼働している最中に AC 供給を止めた時の①⑥の様子を図7に示す。図中 X と記した部分のように AC 供給停止約 7.5 秒後に一瞬の電圧降下がある。この部分のスケールを変えて記録しなおしたものを図8に示す。図のように 10msec 程 3V を下回ることがあり、ここでシステムダウンとそれに続くブートが発生する(さらに数十秒後に SW2 の off に伴い再度システムダウンが起こる)。




図7 USBカメラ接続時の電源供給





図8 電圧降下の様子


この現象の理由について実はよく分かってない。USB カメラが電力(電流)を必要とし、一瞬だけ LTC3118 の能力を超えていることは間違いない。それがなぜ AC 遮断直後でなく約 7.5 秒とずれがあるか不明である(充電電池の充電具合によって時間は多少前後する)。システムが USB カメラに何か指示を与えた時に大量の電力を必要としているのであろう。いずれにせよ USB の先のカメラ等のセンサ機器が原因である。USB 2.0 は Vcc/D+/D-/Gnd の四本の線で構成されている。このうち Vcc を Raspberry PI からの USB、すなわちその基となる LTC3118 から供給するのでなく、図9のように別途 5V を作って与えればよい。実際このように改造した USB ケーブルを用いることで問題なくカメラも動くようになった。



4. まとめと今後の計画

組込み Linux を電源操作で簡単にシャットダウンするしくみを構築した。この技術によって Raspberry PI や Jetson Nano, ひいてはそれに搭載した人工知能アルゴリズムの活躍の場が広がった。今後様々な場面で実践運用していきたい。

一方で今回はケーシング時にコンパクトにまとまることを重要視し、ニッケル水素電池 4 個で済ませることを重要視とした。LTC3118 は昇圧も降圧も出来るがどちらかというと昇圧は不得手という話を聞く。図 8 のような瞬間的な電圧降下はその辺に原因があるとも考えられる。ニッケル水素電池 6 個用いて 7.2V にすればよかったかもしれない。その場合わざわざ LTC3118 を使うまでもなく図 10 のようにダイオード二個と降圧型 DCDC 一個で要求が満たされる。電池に割くスペースが増える分と回路が簡単になってスペースが減る分とが相殺されるかもしれない。引き続き今後も様々な可能性を検討していきたい。



地域の美容業界を対象とした地域課題解決型 AI 教育プログラムの成果

～顔照合受付およびヘアスタイル提案アプリの実装～

情報ネットワーク工学科 河野 央

令和4年3月

1. 研究の目的

本研究は、地域の美容室を展開する株式会社 SIC より AI 応用研究所へ「顧客サービスや店舗経営への AI 活用」について相談があり、本学の AI 教育へのご理解・ご協力の下、AI 活用演習選抜クラスの PBL における地域課題解決テーマとして取り上げたことがきっかけである。コロナ禍における接触回数の減少、さらなる顧客サービスの向上および付加価値の提供として「顔照合による受付」「ヘアスタイルの提案」に対してアプリケーション開発および実装を目指したものである。

2. 期待される効果

顔照合については、実店舗で稼働に必要な機器使用やメンテナンス、連携に必要な情報等、店舗実装に向けた課題を明らかにし、企業ニーズへよりマッチングした提案を行うことができる。また、ヘアスタイル提案については、店員・顧客双方が同じ完成予想イメージを共有することで、接客が苦手な店員、コミュニケーションが苦手な顧客など、言語化が困難なヘアスタイルを共有しやすくなり、より正確な完成度や満足度の向上を期待できる。

3. 研究の経過及び結果

3.1 顔照合について

顔を検出し、個々人の識別、その後照合し何らかの処理を許可する等、顔を利用した受付は無人でも対応できるためコロナ禍の感染防止として採用しやすい。本研究の PBL でも予約の確認、修正まで想定していたが、実際の認証では CRM(顧客管理)等の他システムとの連携が必要なため、顔照合を実装の目標として設定した。顔検出のアルゴリズムとしては、Haar like 特徴量、Deep Neural Network、HoG 特徴量を用いたものが代表的であるが、ここでは Python の Face Recognition ライブラリを用い、モバイル PC の CPU でも十分な処理速度と精度が得られる HoG 特徴による検出・照合を利用し AI 活用演習選抜クラスの学生チームが実装した。照合例を図 1 に示す。




図 1 顔照合および名前（ぼかし部分）の表示結果

十分な処理速度だけでなく、顔が斜めであったり表情が多少変わったり髪の毛で輪郭が隠れていても正しく判定されており、HoG 特徴でも照合は十分であると考え、店舗実装でも導入しやすいと判断した。また、インターフェイスを備えた受付アプリは、実店舗の客層やブランドに合わせ、効果音やアニメーションを用いて直感的な操作で受付処理ができるように Python のビデオゲーム用モジュールである pygame を用いて製作した（図 2-1 および図 2-2）。受付アプリは企業が有する CRM との連携が必要であるので、デモ稼働となったが、顔照合により受付の自動化の敷居の低さを企業に対して示せたのではないかと考えられる。

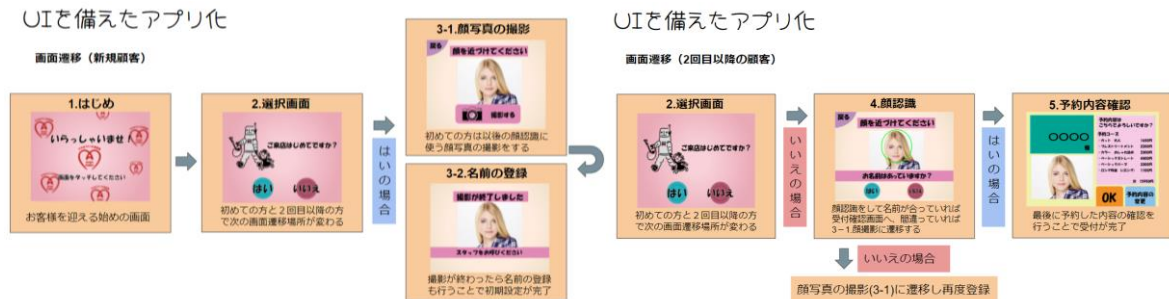


図 2-1 アプリの画面遷移の設計



図 2-2 顔照合と組み合わせた受付の実稼働の様子

3.2 ヘアスタイル提案について

顧客のヘアスタイル提案アプリについては、本研究室4年生の研究テーマとして取り上げ、実店舗での利用を想定してAIを実装・応用することを目指した。

画像生成は StyleGAN[1]を利用した。この深層学習の手法は、生成画像の特徴を Style 変換と呼ばれる正規化手法により制御し、アップサンプリングすることで従来の GANs よりも高精度な画像の生成が可能である。また、潜在変数と呼ばれる生成パラメータを操作することで、生成画像の制御が可能であり、本研究が求めるヘアスタイルを変えた個人の顔画像生成に最も近い手法と考えた。

StyleGAN を実装した結果、髪の毛の長さを変えることが可能になったが、それ以外の潜在変数の詳細の特定、例えば髪型をカールさせたり分けたりといった制御は難しく、さらに髪の毛の長さを変更すると顔のパーツの生成および表示に影響を受けてしまい、元の本人画像と顔が異なり違和感が生じてしまうという問題点があり、解決策を練ることになった。

違和感を減らすためには、生成後に元の本人画像を合成する単純な方法を組み入れた。まず入力画像を読み込んだ後、StyleGAN の face_landmark で顔領域を中心にトリミングし保存しておく。StyleGAN で

髪の長さを変更後、トリミング保存しておいた画像を、髪型に干渉しない領域で輪郭をぼかした円形マスク画像による合成を生成画像に対して行い、合成画像を出力した（図 3-1）。その結果、図 3-2 のように元の入力画像と比較して違和感のない合成画像を得られた。



図 3-1 左: 顔領域を中心にトリミングした入力画像. 右: 円形マスク画像による合成用画像



図 3-2 左: StyleGAN による生成画像. 右: 本研究による出力画像

次に、Tkinter を用いてヘアスタイル提案アプリとして UI 実装を行った。Web カメラ入力画像を取り込み、本人の顔のまま髪の変更できるようになったが、ローカルでの実行時間は、NVIDIA GEFORCE GTX1070 を搭載した PC を使用して 7 分ほど掛かるといった問題もあった。



図 4 UI を実装したアプリと出力画像

4. まとめおよび今後の計画

本研究は、地域課題解決型 AI 教育プログラムの実践として取り組んだ結果をまとめたものである。これらの成果は学生自らが成果発表会で企業に説明したが、企業側のシステム連携等を進める必要があり、実装完了を一つの区切りとした。AI 活用演習選抜クラスの学生は、地域企業のニーズ・課題に対して「実装をしっかりと提案する」という目標やマインドセットを醸成できており、外部教育用コンテンツ(udemy)を有効に活用してその目標を達成したと考えられる。PBL は学ぶ技術のその先のユーザーの顔が見えるため、漠然と学修することに比べて成長実感を持って学修できるのではないかと実感した。不特定多数者に対する顔認証システムの利用については、法的規制の動向に注視しなければならないが、

顧客の明示的な同意のもと顔認証を行うという前提で、利用可能であると期待している。ヘアスタイル提案アプリについては、顧客の髪の色を変更する程度であり、「提案」には至っていないため、継続して研究開発が必要であるとともに、タブレット等で出力画像が数秒で生成できるまで処理速度の向上を図る必要がある。

参考文献

[1] Tero Karras, et al., “A Style-Based Generator Architecture for Generative Adversarial Networks”, arXiv:1812.04948,

対話型 AI 自動運転モビリティの社会実装に向けた人工知能システムの改良

インテリジェントモビリティ研究所 東 大輔, 服部 雄紀
自動車システム工学専攻 太田 遼介, 松永 周大

令和 4 年 3 月

1. 研究背景

内閣府が推進する「Society5.0」は、人工知能や自動運転といった先端技術をあらゆる産業や社会生活に取り入れて新たな価値を創造し、全ての人々が快適で活力に満ちた質の高い生活を送れる人間中心社会を実現するものである。その応用範囲は多岐に渡るが、特に期待されているのが超高齢社会を支える新たな福祉サービスである。我が国は世界でも稀な速度で高齢化が進んでおり、その社会保障費の増大が喫緊の課題となっている。厚生労働省 平成 27 年度介護保険事業状況報告によると、2000 年時点での要介護（要支援）認定者数は 256 万人だったのに対し、団塊世代が 65 歳になった 2015 年には認定者数が 620 万人と 2.4 倍に増加しており、介護保険事業費も増大している。また、団塊世代が 75 歳以上の後期高齢者に達する 2025 年には高齢者割合が 30%に達して社会保障費の確保が難しいと予測されており、政府は「地域包括ケアシステム構想」を提唱し、高齢や 障がいなどで介護が必要な人も可能な限り自立した生活を送れる地域（福祉サービス）づくりを推進している。地域包括ケアシステム構想の高齢者自立支援は行政の介護費削減の意味もあるが、本来の目的は高齢者が自らの意思で自由にいきいきと生活を楽しみ、健康寿命を延ばすことにある。介護者へ遠慮することなく自分の意思で自由に移動することができれば、要介護者を含む 高齢者の社会参画を促すことができ、いきいきとした真の自立生活を実現することができる。介護福祉の世界では「移動支援」 が最も重要なキーワードなのである。

2. 研究目的

本学は 2015 年 11 月にインテリジェント・モビリティ研究所を設立し、開学から強みとする「自動車工学」に、「人工知能」「自動運転」「IoT」を融合した「先進モビリティ技術」で、高齢者や障がい者の移動を支援するスマートモビリティの研究開発に注力してきた。本モビリティは人工知能を搭載し、対話で行き先を相談できるパートナーのような自動運転モビリティであることから、我々は「パートナーモビリティ」と命名して社会実装を進めている。

パートナーモビリティには大きく二つの人工知能を搭載している。一つは安全に自動運転するための危険回避システム。現在は人や物体の認識と距離の推定を行っている。そしてもう一つは、ユーザの趣味嗜好に基づいて行き先提案を行うリコメンドシステムである。本研究では、それら人工知能の改良を進める。

3. パートナーモビリティの主な機能

パートナーモビリティの主な特徴（機能）を以下にまとめる。

- (1) 屋内と屋外の両方に対応する自動運転システム
- (2) 利用者の嗜好に合わせて行き先を提案する対話システム
- (3) 障害物との衝突を回避する人工知能システム

- (4) スマート端末からアクセス可能な WEB アプリ
- (5) 様々なシーンに対応可能なプラットフォーム
(美術館, 観光地, 病院, 空港, 自宅, 職場などに対応)

4. 人工知能の改良

4.1 危険回避システム

上述のように, パートナーモビリティの危険回避システムには既に衝突回避用として人や物体を認識するシステムは搭載されている. 本研究では, 車両が歩道や走行エリアから逸脱しないためのセグメンテーションシステムを構築する.

ネットワーク構築には SONY の Neural Network Console を使用してデータセット作成し, 学習を進めていく. 本研究では, バイナリーセマンティックセグメンテーションと呼ばれるネットワークを使用する. 機械学習においては, 画像をいくつかのオブジェクトに分割するタスクのことを指す.




図1 構築したネットワークの一例

動画で道を含んだ風景を撮り,それらの画像を自動分割して大量のデータを得る.それらのデータを道,草むら,空の3種類の色分けをして,データセットを作成した.




図2 データセット画像の一部

これらのデータセットを使用し,ネットワークを細かく改善して学習させた.



図3 学習過程



図4 推論画像

このように,境界まで明瞭に認識するシステムを構築できた. 歩道からの逸脱を防止できれば, GPS-RTK コンパスの精度が担保できないエリアでも最低限の自動運転が可能になる. スマートモビリティを用いたサービスの実用化に向けて一歩前進することができた.

4.2 リコメンドシステム

レコメンドーションには様々な手法が用いられるが,本研究では単語から特徴を抽出しベクトルに変換する tf-idf (term frequency-inverse document frequency) とコサイン類似度を用いたレコメンドシステムを構築した. 利用者の属性をもとに目的地の属性が出力されることを確認した.

【出力結果例1】

入力 : 20代, 男性, ラーメン, ハンバーガー, デザイン, 美術鑑賞

出力 : 20代, 30代, 女性, 男性, ハンバーガー, ラーメン

【出力結果例2】

入力 : 20代, 女性, 歴史, ハンバーガー, デザイン, 美術鑑賞

出力 : 20代, 30代, 40代, 女性, エレガント, モダン, デザイン, 美術鑑賞

このように入力と出力で属性の類似度が高く、適切なリコmendができていると考える。実際に北九州八幡東田エリアでスマートフォン向けのリコmendアプリを構築し、事前に個人属性を登録した利用者に対して適切なリコmendが行えることを確認した。

5. まとめと今後の計画

本学が産学官連携で開発を進める対話型 AI 自動運転モビリティ「パートナーモビリティ」の社会実装を目的に、屋外での自動運転走行の安全性を高める狙いで歩道領域の認識を行う人工知能システムを構築した。今後は自動走行を行う現場での学習を進め、認識精度を高める。

また、AI 対話システムの利便性を高める狙いで、ユーザーの属性に合わせて行き先を提案するリコmendシステムを構築した。まだプリミティブな内容ではあるが、これをベースにしてより適切なリコmendができるシステムになるよう改良を進める。

小さな例題から始めるニューラルネットワーク

教育創造工学科 松浦 望

2022 年 3 月

1. はじめに

今年度、私の研究室では機械学習の分野を学びたい学生がいた。彼ら 2018 年度入学生は、本学で初年級向けに開講されている「AI 概論」や「AI 活用演習」の授業を受けていない世代なので、卒業研究はニューラルネットワークの基礎知識を学ぶことから始めた。いくつかの入門書を開いてみたものの、ある本は数学的に高度すぎたり、またある本は実装に重点を置いていたりして、数学の立場からニューラルネットワークの挙動が納得できるようになるまでに時間を要した。そこでこの短文では、手で計算できるサイズの小さな例題を軸にして、ニューラルネットワークの数理、特に単純パーセプトロンについて説明したい。以下に述べることに学術上の新規性はないが、初学者がつまづきやすいと思われる箇所を丁寧に説明するから、この教材がこれからニューラルネットワークを学ぼうとする本学学生諸氏の理解の一助になれば幸いである。

2. 小さな例題

座標平面上に、白に塗られた 3 点 $(0, 1)$, $(0, 0)$, $(1, 0)$ と黒に塗られた 1 点 $(1, 1)$ がある。このとき次のような問題を考える。問題「これら 4 点を白のグループと黒のグループに分離する直線の方程式を求めよ」この問題に対する答えは無数にたくさんあるが、その中から適当にひとつだけ答えればよい。

3. ニューラルネットワーク

平面の座標を (x_1, x_2) とすると、私たち人間はすぐに $x_2 = -x_1 + 3/2$ や $x_2 = -(3/2)x_1 + 2$ などの答えを思いつくことができる。このような解答例をコンピュータに見つけさせるにはどうすればよいだろうか。この課題を解決するための手法のひとつがニューラルネットワークである。この節ではニューラルネットワークの数理について簡単にまとめ、これから使う用語を整理する。座標平面上に N 個の点 (x_{11}, x_{21}) , (x_{12}, x_{22}) , ..., (x_{1N}, x_{2N}) と各点に対する分類ラベル $t_1, t_2, \dots, t_N \in \{0, 1\}$ が与えられたとき、平面に直線を引いてこれら N 個の点を 2 つのグループに分けることを線形判別とか線形分類と呼ぶ。上述の例題は $N = 4$ の場合であり、分類ラベルは例えば白を 0, 黒を 1 と解釈すればよい。線形分類を達成するような直線の方程式 $w_0 + w_1x_1 + w_2x_2 = 0$ を探すこと、もっと直接に言えば数値 w_0, w_1, w_2 を探すこと、これがニューラルネットワークの典型的な仕事である。ニューラルネットワークというのは神経回路網の数理モデルを指す言葉で、その最初のモデルである形式ニューロンは 1943 年に神経生理学者のマカロックと数学者のピッツにより提案された。ニューラルネットワークの仕事は線形分類の他にもたくさんあるから、線形分類を専門に行うニューラルネットワークのことを線形分類器と呼ぶことにする。以下では、線形分類器の数理を正確に述べるために

$$X_1 = \begin{bmatrix} 1 \\ x_{11} \\ x_{21} \end{bmatrix}, \quad X_2 = \begin{bmatrix} 1 \\ x_{12} \\ x_{22} \end{bmatrix}, \quad \dots, \quad X_N = \begin{bmatrix} 1 \\ x_{1N} \\ x_{2N} \end{bmatrix}, \quad W = \begin{bmatrix} w_0 \\ w_1 \\ w_2 \end{bmatrix}$$

とにおいて、各番号 $k \in \{1, 2, \dots, N\}$ に対してベクトル X_k とベクトル W の内積を a_k と書く．すなわち $a_k = w_0 + w_1 x_{1k} + w_2 x_{2k}$ であり、この値は活性と呼ばれる．線形分類器は、データ X_k を入力として受けとり、適当な重み W のもとで活性 a_k を計算したのち、さらにそれを適当な非線形関数 σ で評価した値 $y_k = \sigma(a_k)$ を出力する．関数 σ は活性化関数と呼ばれ、いろいろな選択肢があるが、例えば階段関数

$$\sigma(a_k) = \begin{cases} 0 & (a_k < 0 \text{ のとき}) \\ 1 & (a_k \geq 0 \text{ のとき}) \end{cases}$$

や、それを平滑化したような形状のシグモイド関数 $\sigma(a_k) = 1/(1 + \exp(-a_k))$ がよく用いられる．シグモイドというのは、ギリシア文字のシグマ (ς) の形をした、とか、S 字形の、という意味の単語である．



図 1 シグモイド関数のグラフ．点 $(0, 1/2)$ における接線の傾きは $\sigma'(0) = 1/4$ である．ゲインと呼ばれる正の定数 c を導入して $\sigma(a) = 1/(1 + \exp(-ca))$ と修正すると、傾きは $\sigma'(0) = c/4$ に変わる．したがってゲインを大きくすればするほど、シグモイド関数は階段関数に近づく．

与えられた点たちを二つのグループに分ける際、その点たちがはっきりと二分できるような場合は階段関数による線形分類器を用いればよいが、しかし場合によっては分類の境界線がはっきりせず確率的にぼやけたものになっていることも多い．そのような場合に出力値 y_k を確率ととらえ、線形分類を無理矢理行うためのアルゴリズムがシグモイド関数による線形分類器である．すなわち私たちは、線形分類器の出力 y_k がもし $y_k \geq 1/2$ であるならそのデータ X_k をグループ 1 に分類し、もし $y_k < 1/2$ なら X_k をグループ 0 に分類する．始めに指定された分類ラベル t_k と線形分類器の出力 y_k は、すべての番号 k についてぴったり一致する（階段関数を利用するような場合）か、もしくはほとんどすべての番号 k について極めて近い値になること（シグモイド関数を利用するような場合）が期待される．しかし重み W の選び方によっては t_k と y_k の値が大きく開いてしまうような番号 k も存在しうる．理想 t_k と現実 y_k の誤差 $|t_k - y_k|$ の総量 $L = |t_1 - y_1| + |t_2 - y_2| + \dots + |t_N - y_N|$ をいかにして小さく抑えるかを考えるのがニューラルネットワーク理論の肝であり、それを実現するためのアルゴリズムは、ニューラルネットワークの学習と呼ばれている．学習とは、ニューラルネットワークの出力を所望のものに近づけるために、ニューラルネットワークの素子間の結合の強さ、すなわち重み W の値を何度も繰り返し修正する作業のことを指す言葉である．なお関数 L は理想と現実の差を測ることができれば何でもよく、本稿では誤差の和を用いるが、他にも誤差の自乗の和 $L = \sum_{k=1}^N (t_k - y_k)^2$ や、とくに活性化関数としてシグモイド関数を採用した線形分類器の場合には、クロスエントロピーの期待値 $L = - \sum_{k=1}^N (t_k \log y_k + (1 - t_k) \log(1 - y_k))$ を用いるなど、状況に応じて複数の選択肢があり、これらを総称して損失関数という．

4. ニューラルネットワークで例題に答える

第 2 節で述べた例題で与えられたデータに適当に番号をつければ, 表 1 のようになる.

表 1 例題で与えられたデータ

	$k = 1$	$k = 1$	$k = 1$	$k = 1$
x_{1k}	0	1	0	1
x_{2k}	0	0	1	1
t_k	0	0	0	1

この例題は要するに, 論理積を実現する線形分類器をひとつ構成せよ, という問いであり, いろいろな入門書で取り上げられているが, そのオリジナルはマカロックとピッツの論文 (W. McCulloch and W. Pitts, *A logical calculus of the ideas immanent in nervous activity*, The bulletin of mathematical biophysics 5 (1943), pp. 115–133) だろう. さて, 先に説明したようにまずと置く.

$$X_1 = \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix}, \quad X_2 = \begin{bmatrix} 1 \\ 1 \\ 0 \end{bmatrix}, \quad X_3 = \begin{bmatrix} 1 \\ 0 \\ 1 \end{bmatrix}, \quad X_4 = \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix}, \quad W = \begin{bmatrix} w_0 \\ w_1 \\ w_2 \end{bmatrix}$$

したがって活性は $a_1 = w_0$, $a_2 = w_0 + w_1$, $a_3 = w_0 + w_2$, $a_4 = w_0 + w_1 + w_2$ だから, 活性化関数を σ とすれば線形分類器の出力は $y_1 = \sigma(w_0)$, $y_2 = \sigma(w_0 + w_1)$, $y_3 = \sigma(w_0 + w_2)$, $y_4 = \sigma(w_0 + w_1 + w_2)$ となり, 損失 $L = |t_1 - y_1| + |t_2 - y_2| + |t_3 - y_3| + |t_4 - y_4|$ は

$$L = |\sigma(w_0)| + |\sigma(w_0 + w_1)| + |\sigma(w_0 + w_2)| + |1 - \sigma(w_0 + w_1 + w_2)|$$

となる. これは重み W の成分を変数とする 3 変数関数だから, 以下ではそのことを強調して L のことを $L(w_0, w_1, w_2)$ と書く. もし, 損失の値が最小, すなわち $L(w_0, w_1, w_2) = 0$ となるような重み W を見つけることができれば, それが例題の答えである. 以下では, 活性化関数 σ として階段関数とシグモイド関数を採用し, それぞれの場合について, 詳しく計算してみよう.

活性化関数 σ が階段関数の場合. このとき損失 $L(w_0, w_1, w_2)$ は高々 5 つの値 $\{0, 1, 2, 3, 4\}$ しかとらない. 損失関数の挙動を詳しく見るために, w_2 の値を好きなように固定してそれを $w_2 = b$ と書き, 2 変数関数 $L(w_0, w_1, b)$ を考える. 関数 $L(w_0, w_1, b)$ は (w_0, w_1) 平面において 4 直線 $w_0 = 0$, $w_0 + w_1 = 0$, $w_0 + b = 0$, $w_0 + w_1 + b = 0$ で分割された領域ごとにその値が定まる. 関数 L の値をグレースケールで示して $0 = \blacksquare$, $1 = \blacksquare$, $2 = \blacksquare$, $3 = \blacksquare$, $4 = \square$ と色分けすれば, 定義域の (w_0, w_1) 平面において, 関数 L の挙動は図 2 のように図示される.




図2 2 変数関数としての損失関数 $L(w_0, w_1, b)$ の等高線図. 左は $b > 0$ の場合で関数 L の取りうる値は $\{0, 1, 2, 3\}$, 中央は $b = 0$ の場合で関数 L の取りうる値は $\{1, 3\}$, 右は $b < 0$ の場合で関数 L の取りうる値は $\{1, 2, 3, 4\}$.

したがって関数 L が最小値 0 をとるためには $b > 0$ であることが必要である. 私たちの目標は, $w_2 = b > 0$ として, 関数 L の最小値 $L(w_0, w_1, w_2) = 0$ を実現する重みを探すことに帰着された. 最小値を実現する重みは, 図2のいちばん左の図で 色に塗られた領域から好きなように値を取ってくればよい. 例えば $w_2 = w_1 = 1$ のときは, w_0 は不等式 $-2 < w_0 < -1$ さえ満たしていればどんな値でもよく, これを直線の方程式 $w_0 + w_1x_1 + w_2x_2 = 0$ のもとで第2節の例題に照らし合わせてみれば, いかにも尤もらしい答えである. 以上に述べたことは人間が手計算で行った考察である. これをコンピュータに行わせたいが, しかし学習によく用いられるアルゴリズムは活性化関数の勾配を利用するため, 階段関数を使った場合はそのアルゴリズムが機能しない. 仕方がないので, 素朴に例えば[このようなPythonのプログラム](#)を書いてみよう. これを実行すると, 乱数を用いているから実行するたびに出力は異なるが, 例題に対する複数個の解答例が表示される. しかしこのプログラムは, 最終行において, 損失 L の最小値が存在すること, およびその値が 0 であること, の二点を既知としており, データから自動的に直線を見つけられるようにはなっていない点において不満が残る.

活性化関数 σ がシグモイド関数の場合. このとき損失関数は $L = \sigma(w_0) + \sigma(w_0 + w_1) + \sigma(w_0 + w_2) + \sigma(-w_0 - w_1 - w_2)$ となる. 例題ではデータ X_4 だけを仲間はずれにすることが要求されているので, 活性化に対して条件

$$w_0 = a_1 < 0, \quad w_0 + w_1 = a_2 < 0, \quad w_0 + w_2 = a_3 < 0, \quad w_0 + w_1 + w_2 = a_4 > 0$$

を課す. 私たちの目標は, この制約条件のもとで, 関数 L の最小値を実現する重み W を求めることである. もし, この制約条件によって表される3次元空間の開集合内において関数 L が最小値をとるなら, それは極値でもあるから, その場所 W における関数 L の勾配ベクトル $\nabla L(W)$ は零ベクトルでなければならない. すなわち, 最小値を探すための準備として, 私たちはまず連立方程式

$$\frac{\partial L}{\partial w_0} = 0, \quad \frac{\partial L}{\partial w_1} = 0, \quad \frac{\partial L}{\partial w_2} = 0$$

を解く必要がある. ところが, 実際に計算してみればわかるとおり, この連立方程式には実数解が存在

しない. したがって関数 L は最小値をもたない. 関数 L に最小値がないことをもっと感覚的に納得できるように, 階段関数の場合に行った議論と同じように, 変数 w_2 の値を固定して考えてみよう. 制約条件より特に $w_2 > 0$ でなければならないから, 例えば $w_2 = 1$ とする. このとき定義域の (w_0, w_1) 平面において, 関数 $L(w_0, w_1, 1)$ の挙動は図3のようになる.




図3 2変数関数としての損失関数 $L(w_0, w_1, 1)$ の等高線図. 寒色から暖色に向かって関数の値が増加する. 座標は横軸が w_0 , 縦軸が w_1 である. 左図は w_0 と w_1 を -9 以上 9 以下の範囲で動かして描いたもので, 右図は -90 以上 90 以下の範囲で動かして描いたもの. なお右図で直線 $w_0 = 0$ の周辺が黒く見えているのは, 等高線が混み合っているせい.

図3からわかるように, 関数 $L(w_0, w_1, 1)$ は定義域内を傾き -1 の直線 $w_1 = -w_0 + h$ に沿って左上のほうに移動すればするほどその値を減らすことができってしまう. したがって関数 $L(w_0, w_1, 1)$ には最小値が存在しない. ちなみに図3の等高線図は Mathematica (という有償のソフトウェア. 本学では学術情報センターのコンピュータで利用可能) で作成したものだが, もし [Google Colaboratory](https://colab.research.google.com/) でこのような等高線図を作成し, 保存したいなら, [このようなプログラム](#) を書けばよい. さて, 関数 L の最小点を見出すことは諦めざるをえないが, もう少し観察を続けて, 現実的な落とし所を探してみよう. そのためにまず w_0 と h を新たな変数と思って2変数関数 $L(w_0, -w_0 + h, 1)$ の挙動を調べてみると, この関数は, w_0 の値を固定するごとに, $h = -1/2$ において最小値をとることがわかる. したがって私たちの観察は1変数化された損失関数 $L(w_0, -w_0 - 1/2, 1)$ の挙動を見ることに帰着される. この関数は $w_0 \rightarrow -\infty$ のとき限りなく 0 に近づく. 対応する直線の方程式は $w_0 + (-w_0 - 1/2)x_1 + x_2 = 0$, すなわち $x_2 - 1/2 = -w_1(x_1 - 1)$ である. 結局, シグモイド関数を用いた線形分類器は学習によって定点 $(x_1, x_2) = (1, 1/2)$ を通る傾き $-\infty$ の直線に近づくような答えを出してくるであろうことが予想される. そこで[このような Python のプログラム](#) を書いて, この見積もりが正しいか確認してみよう. これを実行すると, 学習後の重みが $w_1 = 25.833265$, $w_2 = 25.833265$, $w_0 = -38.806805$ などと表示される. この重みが表す直線の傾きは -1 で, 切片は 1.5 ほどである. なお, この直線を描く場合は, プログラムの末尾にコードをすこし書き足して, [このようなプログラム](#) を書くとよい. 先ほど見積もったよりも直線の傾きがかなり緩やかだが, この理由を説明しているのが図4である.




図 4 2 変数関数としての損失関数 $L(w_0, w_1, 30)$ の等高線を, w_0 と w_1 を -90 以上 90 以下の範囲で動かして描いたもの. この等高線図が, 図 2 のいちばん左の図とよく似ていること, および, 図 3 の凡例と比べて寒色の表す値がより 0 に近くなっていること, の二点に注目されたい.

すなわち, 始めから w_2 と $-w_0$ の値を適度に大きく (例えば $w_2 = 30$, $w_0 = -90$ など) とっておけば, 損失 L の値をはやく (すなわち学習の epoch 数が少ない段階で) 小さくすることができ, より先ほどの見積もりに近づくことがわかる.

5. おわりに

ニューラルネットワークの例題はすぐにサイズが大きくなってしまふ (重み W が高次元のベクトルになってしまふ) から, ほとんどの場合, 手で計算することができない. 多変数関数の制約つき極値問題を, 解がない場合にも無理やり解かなければならず, 解析的にも数値的にも難しい内容であるように思う. さて, 今年度の卒業研究ではこの短文で述べたような入門的内容を学んだあと, ニューラルネットワークを利用した常微分方程式の数値解法について調べた. これについてはまた別の機会に報告したい.

AI を用いた絣糸耳部の検出

機械システム学科 澁谷 秀雄

令和4年3月

1. 研究の目的

久留米の伝統工芸として久留米絣がある。これは約200年前から福岡県南部の筑後地方一帯で製造されている綿織物で、日本三大絣のひとつと称されている。

久留米絣は、通常の織物とは異なり、括りとよばれる技法を用いて紋様に併せて糸の段階で染色を行い（先染め）、それを平織りすることにより紋様を表現する。このため、図1に示すように、かすんだような独特の風合いを有していることが特徴の一つである。



図1 久留米絣

2. 研究の必要性及び従来の研究

久留米絣の製造は約30工程が必要で完成までに約2～3ヶ月を要している。その一部は機械化されているが、大部分は職人の技能に頼るところが多く、技能伝承や後継者不足、コスト削減といった問題を抱えている。そこで本研究では、これらの問題を解決することを目的として、巻取工程の自動化に必要な要素技術を検討することとした。

先染めした糸を平織りすることにより紋様を表現する久留米絣では、製織の際の糸ズレが柄ズレに直結する。久留米絣では杼で緯糸を通すシャトル織機を用いており、緯糸で柄を表現する場合は図2に示すトングとよばれる治具に付けられたマークと緯糸に一定間隔で付けられた耳（マーク）とを一致させて巻き付け、これをシャトルに取り付けて製織することにより、柄ズレを防いでいる。このため、マーク同士のズレがないようトングに緯糸を巻き付ける巻取工程は非常に重要な工程である。




図2 トング

図3に示すとおり、巻取工程は専用の機械にトングを20本取り付け、職人が目視でマーク同士のズレがないことを確認し、手作業でハンドルを1回転させて巻き取り、次のマークを再び目視で確認してハンドルを1回転させるということを繰り返している。



図3 巻取工程の作業風景

3. 期待される効果

緯糸で柄を表現する絣では、全ての緯糸をマークのズレがないよう巻き取る必要があり、非常に大きな負荷となっている。この巻取工程を自動化できれば、職人の負荷低減、短納期、コスト削減といった効果が期待できる。そこで自動巻取機の開発を視野に入れ、本研究では緯糸の耳（マーク）を検出する技術の開発を行った。

4. 研究の経過及び結果

緯糸の耳（マーク）部検出には画像処理を用いることとした。久留米絣は木綿糸を藍で染色するため、紺色の糸に白のマークとなる。このため、画像を二値化（モノクロ化）処理すれば、検出できると考えられる。しかし、近年は化学染料が用いられるようになり、黄色の糸に白のマークといった淡い色の組み合わせや2色以上に染色する多色化といったことも行われている。このため、糸の色によってしきい値を変える必要があり、現場レベルで職人が最適なしきい値を設定することは困難だと考えられる。そこで、事前にマーク画像を学習させたAIによって検出させることを検討した。

モデルの作成には、犬・猫を分類する2値分類モデルを参考にして、畳込みニューラルネットワークを実装した。また、学習及び検証の画像データとしては、図4に示す薄青色に白マークの緯糸と図5に示す青色に白マークの緯糸を学習させた後、その学習データを用いてマーク画像の判定を行った。



図4 薄青色に白マークの緯糸画像の一例



図5 青色に白マークの緯糸の一例

図6に図4で示した薄青色に白マークの緯糸画像1000枚の学習過程を示す。エポック数の増加とともに正答率（ACCURACY）は増加し、誤差は減少していることがわかる。この学習結果を用いて10枚のマーク画像の判定を行ったところ、2枚は17%と22%の確率でマークではない、すなわち柄であると間違った判定であった。一方、残りの8枚は98%以上の確率でマークであると正しく判定できた。




図6 薄青色に白マーク画像1000枚の学習過程

図7に図5で示した青色に白マークの緯糸画像1000枚の学習過程を示す。薄青色の場合と同様、エポック数の増加とともに正答率（ACCURACY）は増加し、誤差は減少していることがわかる。この学習結果を用いて10枚のマーク画像の判定を行ったところ、10枚全てが63%以上の確率でマークと正しく判定できた。




図7 青色に白マーク画像1000枚の学習過程

次に図 4 で示した薄青色に白マークの緯糸画像 1000 枚と図 5 で示した青色に白マークの緯糸画像 1000 枚からなる合計 2000 枚の学習データを作成した。図 8 に示すとおり、その学習過程は単体で学習させたものと同様エポック数の増加とともに正答率 (ACCURACY) は増加し、誤差は減少していった。また、薄青色に白マークの緯糸画像 10 枚と図 5 で示した青色に白マークの緯糸画像をそれぞれ 10 枚で判定を行ったところ、薄青色に白マーク画像は 8 枚、青色に白マーク画像は 10 枚全てマークと正しく判定できた。




図 8 薄青色に白マーク画像 1000 枚と青色に白マーク画像 1000 枚の合計 2000 枚の学習過程

5. 今後の計画

本研究において、AI を用いた紺糸耳部の検出を試み、10 枚中 8 枚以上の画像を耳（マーク）部であると正しく判定できた。これより、検出の可能性を見いだすことはできたが、全てを正しく判定することはできなかった。耳部と柄部の違いは、染色されていない白い部分の長さのみであり、これは染色条件などによってもばらつきが生じる。このため、緯糸の画像データのみで全ての耳（マーク）を正確に検出することは困難だと考えられる。今後は Tongue のマーク近くにある糸の画像からマークを検出するなど、巻取機の情報を利用することも検討する必要があると考えられる。

謝辞

本研究の遂行にあたり、久留米紺広川町協同組合、久留米紺協同組合より多大なご協力を頂きました。お礼申し上げます。

熱とエネルギーに係る ES と CFD の連成解析手法の開発

建築・設備工学科 山本 竜大

令和4年3月

1. 研究の目的

建築環境工学分野におけるシミュレーションツールは Energy Simulation (ES) と Computational Fluid Dynamics (CFD) に大別される。熱とエネルギーは省エネルギーが急務とされる昨今において非常に重要な予測ツールである。本研究では、建築分野で代表的なシミュレーションツールである ES と CFD を連成する事により精緻な解析結果を得る事を目的としている。

2. 研究の必要性及び従来の研究

例えば従来の ES では、質点で代表する関係から温度成層を解析する事は困難であったしかし、ES と CFD を連成する事によって可能となる。住宅はもちろんの事、非住宅であるオフィスなどにも適用可能な技術として連成解析が存在する。しかし、その難度の高さから既往研究は極めて少ないのが現状である。

3. 期待される効果

期待される成果として熱とエネルギーを精緻に解析可能となる点が挙げられる。それも、非定常解析に対応する事により汎用性の高い解析が可能となる。エアコンに関して言えば、電力中央研究所の開発した機器特性モデルを用いる事で精緻に消費電力を予測する事が可能となる。

4. 研究の経過及び結果

今年度の研究の経過と結果に関して概要をレファレンス番号順に示す。

<査読付き論文>

住宅の高断熱化が近年急速に進んでいる。そのような状況下において最適な空調方式を設計段階で決定する事には一定の需要があると考えられる。本研究では、簡易な計算方法で任意に分割された空間の質点の温度を非定常に予測する解析手法を考案し、精度検証を行った。精度を確認した上で、エアコンの最適配置に関するケース検討を行い一定の結論を夏期および冬期で得た。

近年、消費エネルギーの削減に向けた世界的な施策として SDGs などが挙げられる。そのような取り組みを推進していくに当たって消費エネルギー予測は極めて重要であると考えられる。そこで本研究では、電力中央研究所の開発したエアコンの機器特性モデルを組み込んだ ES と CFD を連成させる事により、吸い込み温度の局所的な温度成層の影響を機器特性モデルに反映させる事によりエアコンの消費電力推定の精度向上がなされる事を確認した。本研究の成果は精緻な消費エネルギー計算による脱炭素社会に向けた技術として有益である。

近年作業環境を気流感が少なく快適に過ごす事が可能な放射空調方式の開発が進んでいる。しかし、住宅においてはエアコンが主流であるため、放射パネルなどの利用はまだ積極的には進んでいない。しかし、放射パネルは現在普及が進みつつあり、現在課題とされている消費エネルギーの課題も解決され

ると予想される。本研究では、放射パネルの消エネ性の悪さを解消する目的で小型エアコンとの併用を考えた際の熱環境を精緻に予測する手法を開発した。本研究で開発した技術は商品開発の場面で大きく貢献するような手法である。実験と解析を組み合わせることで精度検証を成功させた。見逃されていた ES の課題も浮き彫りとして今後の研究の発展が望まれる。

<国際学会発表>

建築分野で物体から空気中の熱輸送を表現する「対流熱伝達率」という用語が存在する。この対流熱伝達率の表現方法としてせん断応力に基づく速度スケールを用いる方法が存在する。この対流熱伝達率の計算方法の精度検証に関して境界層理論を元に行った。結果として、無次元距離 y^+ を参照温度とする事の影響も支配的である事が示されたが、せん断応力に基づく速度スケールで計算された対流熱伝達率の精度は管内流を CFD で再現する事によって確認された。

5. 今後の計画

今後は<査読付き論文> [3] の研究課題に関して除湿や消費エネルギーの相関性を明らかにするような検討を進めていく予定である。また、統計解析を行う事でより精緻な分析を試みる事とする。ニューラルネットワークの利用も想定している。人体熱モデルを利用した人体温熱生理の解明に向けた研究も推し進める予定である。別途地球温暖化の原因である温室効果ガスのメカニズムに関する研究も行う予定である。この研究は建築分野のみならず、世界にインパクトを与える事の出来る研究課題だと考えている。

研究成果の発表

<査読付き論文>

[1] Tatsuhiro Yamamoto, Akihito Ozaki, Myonghyang Lee: Optimal Air Conditioner Placement Using a Simple Thermal Environment Analysis Method for Continuous Large Spaces with Predominant Advection, *Energies* SI:Advanced Environmental Controls for High-Performance Buildings and Sustainability 14(15) 2021.7, IF:3.004, <https://doi.org/10.3390/en14154663>

[2] Tatsuhiro Yamamoto, Akihito Ozaki, Keigo Aratsu: Advanced thermal environment and energy consumption calculation over time using combined energy simulation, computational fluid dynamics, and heat source model, *Journal of Building Performance Simulation*, Vol.14, Issue6, 2021, <https://doi.org/10.1080/19401493.2021.1992503>, IF:3.458

[3] Tatsuhiro Yamamoto, Akihito Ozaki, Myongyang Lee, Keigo Aratsu, Ryo Fukui, Development of a non-stationary thermal environment analysis method for combined convection and radiation air conditioning, *Building and Environment*, Volume 207, Part B, 2022, 108559, ISSN 0360-1323, <https://doi.org/10.1016/j.buildenv.2021.108559>.IF:6.456

<国際学会発表>

[1] T. Yamamoto and A. Ozaki, "Wall Shear Stress-Based Accuracy Verification of Convective Heat Transfer Coefficient Using Velocity Scale," *IECON 2021 – 47th Annual Conference of the IEEE Industrial Electronics Society*, 2021, pp. 1-5, doi: 10.1109/IECON48115.2021.9589217.

陸上競技における次世代風速計開発に向けた基礎的実測

建築・設備工学科 山本 竜大
情報ネットワーク工学科 千田 陽介
教育創造工学科 中嶋 康博

令和4年3月

1. 研究の目的

現在、陸上競技場の風速計は100mの中央部の1レーン寄りに設置されることが日本陸上連盟によって義務付けられている。しかし、選手の実感として、例えば0.5m/sの風速が吹いていたと仮定すると同じ体調やコンディションでもタイムが異なることがあることが挙げられる。この理由として選手にかかる風圧力の影響が強大であることがまず挙げられるが、風向風速の影響度を正確に考慮していないからであるというのがかなりのウェイトを占めている。これまで風速風向に関する影響は若干の知見はあるが、陸上競技のルール改定が行われるほどの知見は集積されていないのが現状である。陸上競技場の風速分布を3次元で捉えることにより試合の際の風速の偏在を明らかとすることが可能となる。従って、本研究では、陸上競技場の風速分布の偏在を精緻に実測し、統計的アプローチによりレーン毎の選手への寄与を把握することを目的とする。最終目標としては、世界陸上などのルールを改訂し、陸上競技の選手が不利益を被らない測定システムを構築するためのエビデンスとして、基礎的なデータベースを構築することにある。

独自に開発する三次元センサに基づき、陸上競技場の実測調査を行う。都市街区の複雑な乱流プロファイルの影響を受けた陸上競技場の風速・風向の実測調査は事例が存在しないことから高い学術性を有している。また、将来の陸上競技の在り方を「創造」という意味において、創造性は極めて高い研究課題である。

2. 研究の必要性及び従来の研究

三次元センシングによる風速分布の把握 人体に対する空力解析は数は少ないが行われている。しかし、実際に人体にかかる風向・角度によって圧力が変わってくる。更に、骨格に応じて風圧力に対するフォームへの影響度にも相違が生じる。また、人によって身体の操作性の能力値は異なるため、風圧力に対応する力も異なる。このように様々な項目を考慮する必要があるため、三次元での風速分布の実測値を得る事は極めて重要であると言える。

統計処理に基づく陸上競技場の三次元風速分布の作成 得られた実測値は統計的処理を用いてその誤差分析を行う事が極めて重要である。また、通常型クリギングによる空間分布の詳細化を行うことにより複数の実測値からより多くのデータを生み出すことが可能となる。更に、推定精度の評価まで行うことで妥当性の確認を行う予定である。場合によっては空間的自己相関の影響も考慮する必要性が生じる可能性がある。都市環境工学では用いられる統計処理ではあるが、スポーツ医学に応用できる萌芽的研究分野に応用されている事例は見受けられない。

3. 期待される効果

陸上競技における風速計の規格 日本陸上競技連盟では風速計の規格を定めており、選手に不利益が被らないように工夫をしている。その性能表示もかなりの分解能で計測が可能な仕様となっている。しかし、100mの中間地点に配置するような工夫がなされている。

陸上競技場の風速分布の偏在 陸上競技場の風速分布は都市街区の影響などを受けて分布が生じている。これは学術的な知見として集積されていないのが現状ではあるが、選手は頭を悩ませている部分ではある。

陸上競技場の風速分布実測上の課題 陸上競技場を実測するのが現状の課題を浮き彫りにするため望ましいと考えられる。しかし、センサの数なども多く必要であるため、高価であるセンサを数十個も購入する事は現実的では無いと考えられる。また、風速計の分布を考慮する際には不確かなどによる統計的な誤差分析は必要不可欠である。

風速計の作成 風速・風向センサの回路自体は製作事例も多く単体ではあまり新規性はない。しかしこれをアレイもしくはメッシュ状に多数並べ、多数(多地点)の情報を同期を取って一か所に集めて統合的に扱う事例はない。このような目的のためには、一個一個が比較的安価であること、学生でも製作可能こと、安定した通信手段や長時間駆動可能な消費電力など多方面から検討しなければならず、そのようなシステムを構築することに意味がある。

風速計の精度検証 一個のセンサにかけることの出来る製作費を考えると、個々の風速計の精度は日本陸上競技連盟の規格を満たさない可能性は高いであろう。しかし、それを多数用いて統計的に扱うことで上記規格に匹敵する精度をめざす。統計的处理によるセンサ情報の補間は例えば天体望遠鏡の写真解析などでは事例があるがリアルタイムに行う所に新規性がある。

風速分布の統計処理 得られる風向のデータはベクトルであるが、まずはスカラーである風力について、文献[横山]を参照して処理する。その後、ベクトルについての処理も検討したい。

風向のデータ処理については、まず(1)各地点のデータから密度関数を推定する。これは正規分布に近似できると予想されるが、正規性の検定にて確認する。またレーンおよび100m走の各地点の違いについて、密度関数を比較する。

次に(2)通常型クリギングによる空間補完法で、風力の空間分布を詳細に把握し、各レーンの、選手が受ける影響を評価する。

また(3)実測の不確かさについて評価する。先行研究[横山ら]では、メッシュが大きくなると局所的な把握が難しくなることを、中心極限定理による統計量を用いて言及している。都市部の道路と陸上のレーンという類似性が低い対象ではあるが、これにならい風向の局所的な差異がメッシュの大小で生じるか検討したい。

作成した風速計を用いて陸上競技場を実測調査 精度を確認したセンサを用いて実際の陸上競技の試合の際に風速分布を実測調査することには大きな意義が存在する。100m、200mのみではなく、400m特有の一周追い風の状態のことを示す「400 風」の現象の解明も期待できる。段階的に100m、200m、400mに向けた風速分布の実測調査を行うことにより個別具体的な課題が明らかとなると予想される。当然ではあるが、都市街区の複雑な風速がプロファイルで流入してくるため、数値流体解析では明らかに出来ない部分が解明される事が期待できる。

4. 研究の経過及び結果

現在の研究の進捗状況は大きく2つに大別される。

4.1 風向を考慮しない簡易実測

風向は考慮していないが風速の大きさで各測定点と IAAF で規定されている測定基準の測定点と比較したところ、相違が見受けられた。統計処理としてクリギング補間を行い、各レーンに風速分布が生じている事が明らかとなった。

4.2 センサに風見鶏を取り付けた風向を考慮した詳細実測

風速計に風見鶏を設置して再度実測を行った。現在測定データは整理中である。

5. 今後の計画

2 回の実測結果は成果を取りまとめて査読付き論文に投稿予定である。今後は、安価なセンサを量産して、400mトラック全体の風速分布を測定可能なシステムを構築していく。最終的には試合中に風速分布を測定し、IAAF の測定結果と比較する事で測定基準の改定の必要性を確認する。測定点が多いのが課題となるため、デジタルツインの利用も視野に入れている。そのためにはデータベース化が必要不可欠である。

研究成果の発表

<投稿採録>

[1] 山本竜大, 千田陽介, 中嶋康博: 次世代風速計の開発に向けた基礎的データベースの構築—簡易実測による分布特性の定量化—, 日本陸上競技学会第20回大会号, 岩手大学, p.29, 2022.2

AI を用いた空調用エネルギー削減技術の検討

AI 応用研究所	呉 濟元, 小田 まり子, 新井 康平
情報ネットワーク工学科	千田 陽介
PC サポートセンター	八坂 亮祐

令和 4 年 3 月

1. 研究の目的

建築物は一度建築されると次の改修や建替えが数十年先となる性質で、多くの建物は竣工時の調整のままで空調設備が運転されている。そこで実際に在室者によってどのように空調設備システムが使われているかについて調査を行い、省エネ的な運転手法を検討する。本研究では、空調設備システムの BEMS データ、小型カメラ、データロガーを用いて収集したデータを AI の画像認識技術による在室者の行動を検知し、その行動における室内の環境、空調設備システムの運転性能検証ツールを開発する。

2. 研究の必要性及び従来の研究

日本の 2050 年カーボンニュートラル宣言を含め世界的に脱炭素への動きが加速化している。第 6 次エネルギー基本計画（案）では、2030 年における省エネの実現が謳われており、その中心は住宅・建築物における大幅なエネルギー消費量の削減が求められている。建物に導入された空調設備システムは使い込まれていくうちに経年劣化等で性能が徐々に変化している。また、室内を使用する人員数、OA（Office Automation）機器による発熱なども空調設備の性能に影響を与えることから、現実のビルの特徴を把握し、その状況に合わせて設備機器・システムを無駄のないように自ら調整・運転する必要がある。近年、センシングや IT（Information Technology）・IoT（Internet of Things）などの技術とナッジに代表される行動科学を組み合わせ、個人や世帯のエネルギー使用実態、属性情報等のビッグデータを IoT 技術である BI-Tech（Behavioural Insights × Technology）が注目されている。それで、本研究では建物利用者への情報収集と提供等により、省エネルギー行動を促し、省エネルギー意識を高めることが重要であるため、AI 技術と空調設備システムの省エネ行動手法の開発に着目した。

3. 期待される効果

BI-Tech を利用して過去蓄積されたデータから最新のデータまで空調設備システムの運転性能を分析して機器の不具合や AI の画像認識技術を用いてリアルタイムで室内の物体認識、在室者の行動を検知し無駄な使い方の行動パターンが分析できる。これらのデータを AI に学習させて省エネ行動変容に繋げる。

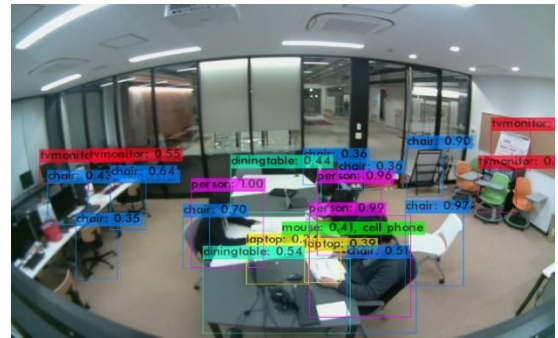
4. 研究の経過及び結果

久留米工業大学 100 号館を対象に導入された空調設備システムの運転データを用いて運転性能を分析した。また、小型カメラを利用して収集した画像データを AI の画像認識技術の YOLOv3 と Openpose を用いて OA 機器や在室者の動作を検知した（図 1）。しかし、モデルの学習済みでない物体に関しては誤認識されることが分かった。室内の窓ブラインド制御による窓の表面温度が 1℃～3℃程度の差が生じた

(図2)．また、室内の明るさは基準値（設計値）より 250 lx 程度高いことが分かった（図3）．




(a) 在室者の様子



(b) 在室者と OA 機器の物体認識




(c) 在室者の動作




(d) 省エネ行動の骨格認識

図1 AIの画像認識技術を用いた画像分析




(a)ブラインドを閉めた時




(b)ブラインドを開けた時

図2 ブラインドによる窓の温度分布（2021年10月11日）



(a) 照度推移



(b) 温度推移

図3 室内の温熱環境

5. 今後の計画

今回行った実験結果では画像認識率が低く誤認識されることが分かった。今後は学習用のデータを充実させて画像認識率を向上させる。また、窓ブラインドの自動制御による室内の環境分析と省エネ行動変容についてフィードバックを通じて省エネ行動に結びつける。

研究成果の発表

<査読付き論文>

[1] 呉済元, 住吉大輔, 小田まり子, 新井康平, 千田陽介, 八坂亮祐: AIを用いた空調用エネルギー削減技術の検討 (AIの画像認識技術を用いた在室者の行動検知と空調設備システムの性能検討), 久留米工業大学研究報告, 第44号, 2022.03 (掲載予定)

帯水層蓄熱システムの効率的な運転方法の検討

AI 応用研究所 呉 濟元

令和 4 年 3 月

1. 研究の目的

帯水層は、透水性が比較的高い砂層等の地下水で満たされた地層を指す。既存蓄熱システムの水蓄熱システムと同様に、夜間に蓄熱を行い、昼間に使用することでエネルギー需要の分散や電力負荷のピークカットなどの電力需給バランスを意識したエネルギー管理が期待できる。本研究では帯水層蓄熱システムが組み込まれた空調熱源システムを対象としてシステムの特性を明らかにし、効果的な運転方法を提案することを目的とする。

2. 研究の必要性及び従来の研究

近年、脱炭素による再生可能エネルギーの利用が進められている。欧州を中心に地盤内の帯水層に熱源機で製造した冷温水を送り、蓄熱する帯水層蓄熱システムが普及し始めている。帯水層蓄熱システムでは既存蓄熱システムの運転方法である日間蓄放熱だけでなく、夏に貯めた温熱を冬に使うような季節間蓄熱や汲み上げた地下水を空調用の熱源水として直接利用するなどの運用方法も考えられ、より省エネルギー性の高い蓄熱システムを構築できる可能性がある。

3. 期待される効果

日本におけるこれまでの帯水層蓄熱システムの状況では、小規模なものが融雪の目的で導入される事例は多かったものの、建物の蓄熱システムとしての利用は試験的な導入に留まっていた。しかし近年、大規模な帯水層蓄熱システムを採用した事例が現われ、本格的に利用され始めている。そのため、帯水層蓄熱システムの効果的な運用方法の検討が必要である。

4. 研究の経過及び結果

研究成果の発表順に研究内容を要約する。

[1] 太陽光発電パネルの余剰エネルギーを利用した帯水層蓄熱システムの運転方法を検討した。また、余剰エネルギーが多く発生する中間期に帯水層に熱を貯めて必要とする時間帯に利用する季節間蓄放熱の運転を検討した（表 1）。図 1 に余剰エネルギーを利用したケーススタディ結果を示す。余剰エネルギーを利用することで夜間蓄熱運転をしなくても昼間の空調負荷を効率的に処理できることが分かった（図 1 (d)）。季節間蓄放熱運転では帯水層熱回収率を 80%程度としたため、熱を貯めて行くうちに熱損失が発生して季節間の蓄放熱運転効果が少なかった。帯水層熱回収率を向上させれば運転効果が高くなると考えられる。

[2] 既存蓄熱システムである水蓄熱システムと帯水層蓄熱システムの運転方法を比較し、帯水層蓄熱システムの効率的な運転方法を検討した。従来の蓄熱システムは夜間に熱を貯めて昼間に放熱する運転を行っている。帯水層蓄熱システムを従来と同様な運転したケース、予冷・予熱コイルを用いた運転ケースを比較した（図 2）。図 3 に蓄熱システムの運転比較（8 月 9 日）を、図 4 に季節間のエネルギー消費

量と運転効率を示す。帯水層蓄熱システムは予冷・予熱コイルを用いた運転方法が蓄熱された温度が変化しても長時間運転が行われた（図3（b））。更に蓄熱温度制御による効率的な運転ができた(図4）。

表1 余剰エネルギーの発生タイミング

Month\Hour	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23
1	0	0	0	0	0	0	0	0	0	0	0	2	3	2	0	0	0	0	0	0	0	0	0	0
2	0	0	0	0	0	0	0	0	0	0	1	1	2	2	0	0	0	0	0	0	0	0	0	0
3	0	0	0	0	0	0	0	0	0	1	1	6	9	5	2	0	0	0	0	0	0	0	0	0
4	0	0	0	0	0	0	0	0	0	2	9	10	13	8	3	0	0	0	0	0	0	0	0	0
5	0	0	0	0	0	0	0	0	0	9	17	19	20	17	10	0	0	0	0	0	0	0	0	0
6	0	0	0	0	0	0	0	0	3	4	9	9	11	8	4	1	1	0	0	0	0	0	0	0
7	0	0	0	0	0	0	0	0	0	2	5	4	5	3	3	0	0	0	0	0	0	0	0	0
8	0	0	0	0	0	0	0	0	1	3	4	3	3	3	1	0	0	0	0	0	0	0	0	0
9	0	0	0	0	0	0	0	0	3	5	8	8	8	5	0	0	0	0	0	0	0	0	0	0
10	0	0	0	0	0	0	0	1	3	10	14	16	15	13	7	1	0	0	0	0	0	0	0	0
11	0	0	0	0	0	0	0	0	0	3	5	10	11	5	1	0	0	0	0	0	0	0	0	0
12	0	0	0	0	0	0	0	0	0	0	1	3	2	1	0	0	0	0	0	0	0	0	0	0




図1 余剰エネルギーを利用したケーススタディ




図2 空調設備システムの系統図





図3 蓄熱システムの運転比較 (8月9日)




図4 季節間のエネルギー消費量と運転効率

5. 今後の計画

今後は帯水層の熱回収率における帯水層蓄熱システムの効率的な運転方法を検討し、帯水層蓄熱システムを導入した実在の建物を対象に運転方法を検証する。また、再生可能エネルギー（太陽光発電等）や都市エネルギー（排熱等）を組み合わせた帯水層蓄熱システムの運転効果を明らかにする。

研究成果の発表

<査読付き論文>

- [1] Oh, J., Sumiyoshi, D., Nishioka, M., Kim, H. Efficient Operation Method of Aquifer Thermal Energy Storage System Using Demand Response. *Energies* 2021, 14, 3129. <https://doi.org/10.3390/en14113129>
- [2] Oh, J., Sumiyoshi, D., Nishioka, M., Kim, H. Examination of Efficient Operation Method of ATES System by Comparison Operation with WTES System of Existent Heat Storage System. *Appl. Sci.* 2021, 11, 10321. <https://doi.org/10.3390/app112110321>

プログラミング学習を支援する画像診断 AI チャットボットの試作

PC サポートセンター 八坂 亮祐

AI 応用研究所 小田 まり子, 呉 濟元

令和 4 年 3 月

1. 研究の目的

プログラミング初学者が学習を進める上で頭を悩ますことの 1 つに、プログラミング実行時エラーの対処がある。本研究では、プログラミング初学者の学習をサポートする目的で、ユーザがエラーメッセージ部分のスクリーン画像を送信すると、エラー原因と対処法を返答する AI チャットボットを試作する。

2. 研究の必要性及び従来の研究

プログラミング初学者は、作成したプログラムの実行時に直面するエラーの原因が特定できず、苦勞することが多い。一般的に、プログラミング学習者はエラー原因が記されたエラーメッセージを頼りに作成したプログラムを見直し、誤りを発見・修正するプロセスを通してプログラミングスキルが向上する。しかし、これにはエラーメッセージの理解とエラーに対する適切な対処が必要で、このスキルを身につけるには、一定の時間を要する。しかし、スキル向上に不可欠である一連のプロセスは、初学者には負担が大きく、学習意欲の低下に繋がる恐れもある。そのため、プログラミング初学者のスキルアップを妨げない方法での補助的支援が望まれる。そこで、本研究ではプログラミング学習を支援するスクリーン画像診断 AI チャットボットを試作した。本チャットボットにユーザがエラーメッセージ部分のスクリーン画像を提示すると、チャットボットはエラー原因と修正方針を返答する。本チャットボットの実践として、久留米工業大学 (以下、本学) で開講されている全学共通科目「AI 概論」および「AI 活用演習」内での試用を予定している。この 2 科目の講義内容に組み込まれた Python による実践演習の支援を行う。

情報通信技術の発展に伴い、爆発的に利用が広がった Facebook や LINE といったソーシャル・ネットワークワーキングシステム (SNS) においてもチャットボット機能が追加され、世間一般でもチャットボットは広く認知されるようになった。近年、大学においても教育支援や問い合わせ対応、情報提供などを目的としてチャットボットが利用されている。2021 年度には、本学においても「AI 概論」に学生からの問い合わせに対応する AI チャットボットを導入した[1]。このチャットボットは学生が普段親しみのある LINE 上に組み込んだ。学生が送信したテキストメッセージをチャットボットが受信すると、学習済みの内容であればチャットボットは適切な回答を返信する。チャットボットには、出欠や試験など講義一般、プログラミング実践演習におけるプログラムの文法や実行時エラー、PC の基本操作方法などに関する問い合わせが寄せられた。チャットボットは多くの問い合わせには適切に回答でき、また利用した学生からのフィードバックによると、チャットボットからの回答により問題が解決した学生が多かった。しかし、プログラミング実行時エラーに関する問い合わせでは次のような問題が生じた。

- (1) 学生自身がどのようなエラーが発生しているか把握できていない
- (2) 学生がエラーメッセージの解釈を上手くできていない

(3) エラー内容を上手く言語化できないため、チャットボットに問題点が伝わらない

3. 期待される効果

前節で挙げたように、プログラミング実行時エラーの問題点を把握できず、上手く言語化できない場合、教科書等の資料を参照してもヒントとなる箇所は見つけづらく、従来のチャットボットに問い合わせしても適切な回答は得られにくい。今回開発したチャットボットにはスクリーン画像診断 AI を搭載した。ユーザは PC 上に表示されたエラーメッセージの箇所をスマートフォン等でエラーが生じた画面を写真に撮り、LINE 上でその画像を送信することで、エラー解決の糸口となる情報を得ることができる。本研究では、プログラミング初学者にエラーを解決する手段を提供することで、意欲を失わずに学習を続けられる効果を期待する。

4. 研究の経過及び結果

本研究では、昨年度に「AI 概論」に導入した AI チャットボットを発展させ、画像診断機能を実装した。本チャットボットの概観を図 1 に示す。システムのベースは LINE プラットフォームである。LINE プラットフォームと API やオンラインサービス等の相互接続には Node-RED を利用した (図 2)。画像認識に対応させるため、Node-RED には Teachable Machine を接続した。Teachable Machine は AI による画像認識モデルが作成可能な Web ブラウザアプリケーションである。今回、Teachable Machine 上では、Name Error (変数に関わる定義エラー) および Syntax Error (構文エラー) が表示されたエラーメッセージ画像をそれぞれ 30 枚ずつ学習させたモデルを作成した。今後より詳細な検証が必要となるが、両エラー画像 15 枚ずつ、合計 30 枚の画像をテストデータとしてモデルの識別精度を検証した。Name Error は 100% (15/15)、Syntax Error は 約 87 % (13/15) の識別精度であった。




図 1 本チャットボットシステムの概観

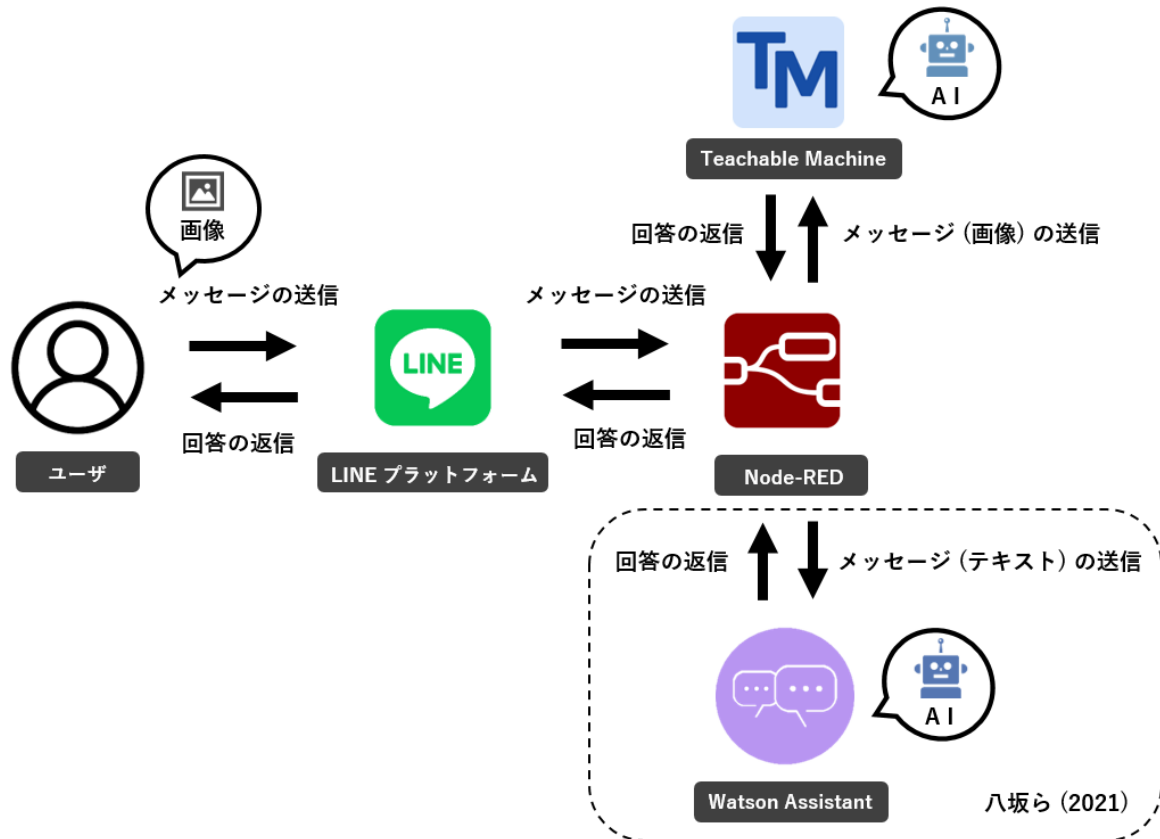


図2 本チャットボットで利用した Node-Red におけるノード間接続

本チャットボットを利用するには、ユーザは LINE 公式アカウントを友だちとして登録する。ユーザがこのアカウントに向けて画像メッセージを送信すると、LINE プラットフォームにメッセージが送信され、Node-RED を介し、Teachable Machine に画像データが渡される。Teachable Machine 上では、受信した画像データが前述の2クラスのどちらに分類されるかを判定し、結果を返答する。返答メッセージは Node-RED を介し、LINE プラットフォームからユーザに送信される。本チャットボット利用画面を図3に示す。今回はエラー原因を提示するのみとなっているが、今後その対処法も併せて提示できるよう改善する。なお、ユーザが送信したメッセージの属性 (テキストあるいは画像) によって、Node-RED がメッセージの送信先を Watson Assistant と Teachable Machine の適切な方に振り分けるよう設定した。



図3 本チャットボットの利用画面

5. 今後の計画

現段階のチャットボットでは画像の識別精度と識別可能なエラーのバリエーションが不十分と考える。したがって、より多くのエラー画像を使用したモデル構築が求められる。また、Teachable Machine は導入が簡易である反面、機械学習モデル設計（ハイパーパラメータの調整）の自由度が低い。今後実用化を目指すには、より自由度の高い機械学習モデル作成方法を検討する必要がある。次年度の「AI 概論」あるいは「AI 活用演習」での本チャットボットの利用を目標に開発を進める。

研究成果の発表

<参考文献>

[1] 八坂, 小田, 原, “講義における疑問を自己解決するための AI チャットボット-「AI 概論」での試験的利用-”, 久留米工業大学研究報告, 43, 2021

<卒業論文>

[1] 荒巻, “AI プログラミング (Python) の疑問を解決する AI チャットボットの開発”, 久留米工業大学情報ネットワーク工学科卒業研究, 2022

AI を活用したキュウリの栽培支援アプリケーションの開発

PC サポートセンター 八坂 亮祐

AI 応用研究所 小田 まり子, 呉 濟元

令和 4 年 3 月

1. 研究の目的

作物栽培は作物を栽培する人間の経験や勘により成否が分かれる。作物に必要な水分量、最適な施肥の量とタイミング、病虫害発生予察など、長年の経験を以ってこれらの感覚を磨くことで栽培技術は向上していく。すなわち、農業初心者にとっては、作物栽培はハードルが高く、その過程で問題が生じやすい。そこで本研究では、これら問題を AI が解決し、農業初心者の作物栽培を支援するアプリケーションの開発を行った。本年度は初年度であるため、まずは対象作物を家庭菜園でも人気の「キュウリ」とし、AI による画像認識技術を応用しやすい「病害の診断」を中心に行うこととした。

2. 研究の必要性及び従来の研究

近年、自ら栽培した野菜を摂取したいと考える健康志向の人が増加しており、家庭菜園や週末農業が注目を浴びている。それら小規模農業は手軽に始められ、楽しめることが魅力である一方、農業初心者にとって作物を安定的に栽培することは難しい。理由の 1 つとして、作物や環境を相手にするため、作物の個体差、病害の発生、天候条件など簡単にはコントロールできない因子が多く存在することが挙げられる。熟練の農業従事者でない限り、それら因子による影響を最適な栽培条件の範囲内に調整することは難しい。そのため、本職ではなく趣味程度で農業を行いたいと考える人にとっては、その知見や感覚を得るためのコストは出来るだけ払いたくない。本研究では、農業初心者が AI を利用することで、いかに少ないコストで熟練の農業従事者の感覚に近づき、上手く作物栽培を行えるかに挑戦する。最近では、作物栽培の基礎的な知見の蓄積や測定技術の向上により、あらゆるパラメータを客観的なデータとして表すことが可能となってきた。気温、湿度や日照量など、パブリックドメインとして公開されているデータも多い [1]。それらを活用した作物栽培に関連する Web やスマートフォンのアプリケーションは少ないながらも既に存在する。しかし、AI を組み込んだアプリケーションはこれまでほとんどない。本研究のポイントは栽培の経過観察から病害への対処など、AI が作物栽培を包括的に支援するところにある。

3. 期待される効果

小規模であっても農業への参入障壁は未だに高い。本研究で開発したアプリケーションによって、作物栽培を行うことに対する心理的ハードルを下げる効果が期待できる。また、作物栽培の経験がなくても、AI による支援がガイドラインとなり、作物栽培の成功確率を高めることに寄与できると考える。

4. 研究の経過及び結果

本年度は主に本アプリケーションの基盤構築および AI を利用した病害診断システムの開発を行った。その他には今後、気象データを利用した栽培アドバイス機能、および AI に栽培に関する相談が可能な

チャットボット機能を実装する予定としている。本アプリケーションの概観を図1に示す。ユーザビリティ (UI) と利用導線を考慮し、最も利用頻度が高いと予想されるソーシャルネットワーキングサービス (SNS) を起点に他機能へ繋がるよう展開する仕組みとした。




図1 アプリケーションの概観

本アプリケーションの SNS は既存サービスと同様にユーザ間でのコミュニケーションを可能としている。ユーザは写真付きのコメントを投稿でき、その投稿を閲覧した他ユーザから「いいね」やコメントでリアクションを受け取ることができる (図2)。本機能は SNS 特有の楽しさにより、本アプリケーションを始めるきっかけ作りや利用継続に繋がることを狙いとしている。バックエンドシステムは Python のフレームワークである Django [2] をベースに構築した。データベースにユーザ情報の登録を行う際には、メールアドレスと対応する任意のパスワードを設定する。本システムへのログイン時はそれらを利用してユーザを識別する。フロントエンドシステムには JavaScript のライブラリである React [3]、外部環境への公開には ngrok [4] を利用した。




図2 SNS アプリケーションのトップ画面

キュウリの病害診断に関しては、キュウリに対する被害が大きく、発生率の高いうどんこ病およびべと病を対象とした。キュウリの健全葉、うどんこ病およびべと病の標徴を示す葉の写真を株式会社久留米原種育成会の敷地内にて撮影し、それぞれ 35, 48 および 60 枚ずつ利用することで、3 者を判別可能

な畳み込みニューラルネットワーク (CNN) のモデル構築を目指した。しかし、これらのデータ数では十分な学習が難しいと考えられたため、学習済みモデルである VGG-16 を用いて 2 段階転移学習を行った。第 1 段階目の学習では、葉の形状を判別できるよう特徴表現を獲得させ、第 2 段階としては葉の模様 (健全、うどんこ病およびべと病の病斑) を判別できるよう CNN を構築した。CNN の構築には Keras [5] および Tensorflow [6], 画像処理には Pillow [7], Web アプリケーション開発には Flask [8] の各 Python フレームワークを利用した。診断結果画面では、ユーザが AI に提示した画像と共に分類区分と判定精度を提示するようにした (図 3)。今後、判定結果だけでなく、各病害への対処法を併せて提案する予定としている。




図 3 AI によるキュウリの病害診断結果;(a)健全葉, (b)うどんこ病感染葉, (c)べと病感染葉

気象データに基づいた撒水や農薬散布などに関する助言を AI が行う栽培アドバイス機能の実装を目指している。気象庁が公開しているデータを Web スクレイピングで取得することは可能となった。現在、前処理および分析方法について検討を行っている。また、ユーザが栽培に関して不明点があった場合に相談可能なチャットボットの開発にも取り組んでいる。チャットボットには AI を組み込み、自由度の高い会話を行えるようにする。

5. 今後の計画

以下の計画で今後の研究を進める。

病害診断システムの分類モデル性能評価および判別精度の向上テストデータでは健全葉をべと病感染葉と判定するなど、不正確な分類を行うことも多かった。訓練データが少なく、学習が不十分であることが原因と考えられる。正確な判別精度を算出した上で、より多くの画像データを収集後、モデルの再構築を行う。

キュウリ以外の作物にも対応家庭菜園や週末農業等で人気の作物にも対応するよう機能を拡充する。作物栽培のスキルアップに寄与する機能の実装本アプリケーションを利用した作物栽培には、本来経験で得られたはずの作物栽培に関する知見や勘が得られにくいという側面がある。小規模農業をする上での楽しみの 1 つである成長機会を奪ってしまうならば、本末転倒である。そこで、作物栽培におけるスキルアップに寄与する機能の実装を予定している。作物栽培におけるコストを最小限に抑え、同時に作物栽培スキルを高めてくれるアプリケーションを目指したい。

アプリケーションの実証実験実際に本アプリケーションを農業初心者にも利用してもらい、アンケート等でフィードバックを受ける。それらに基づきユーザ視点に立ったシステムの問題把握と改善を行う。AWS (Amazon Web Services) または Microsoft Azure (Azure) を利用して公開

研究成果の発表

<参考文献>

[1] 小田, 呉, 新井, 八坂, 河野, 巽, リー, “地域と連携した課題解決型 AI 教育プログラム- 「AI 活用演習」 選抜クラスでの PBL の実践的取組み -”, 久留米工業大学研究報告 44, 2022 (掲載予定)

引用文献

- [1] 気象庁|過去の気象データ・ダウンロード <https://www.data.jma.go.jp/gmd/risk/obsdl/>, (2022 年 3 月 16 日)
- [2] Django, <https://docs.djangoproject.com/ja/4.0/>, (2022 年 3 月 16 日)
- [3] React, <https://ja.reactjs.org/>, (2022 年 3 月 16 日)
- [4] ngrok, <https://ngrok.com/>, (2022 年 3 月 16 日)
- [5] Keras, <https://keras.io/ja/>, (2022 年 3 月 16 日)
- [6] Tensorflow, <https://www.tensorflow.org/?hl=ja>, (2022 年 3 月 16 日)
- [7] Pillow, <https://pillow.readthedocs.io/en/stable/>, (2022 年 3 月 16 日)
- [8] Flask, <https://flask.palletsprojects.com/en/2.0.x/>, (2022 年 3 月 16 日)