

機械学習を用いた農作物の等級判別

ー農業における PBL の実施に向けた検討ー

Classification of Agricultural Crops using Machine Learning

-Toward the Implementation of PBL in Agriculture-

神谷 達夫, 山田 篤

Tatsuo Kamitani, Atsushi Yamada

要旨

本稿では、農業における産業 PBL の実施に向けて機械学習を用いて農作物の等級を判定する「AI 等級判別システムの構築」を試み、試行実験を実施した。試行実験の結果、農業における AI を含む IT 技術の導入は、学生らの PBL に適していることが確認できた。今回の試行実験の結果をもとに、学生らの PBL 教材が構築できると考えられる。

キーワード: PBL, スマート農業, AI, ニューラルネットワーク, TensorFlow, Keras

1. はじめに

「新たな未来を築くための大学教育の質的転換に向けて～生涯学び続け、主体的に考える力を育成する大学へ～（答申）」⁽¹⁾では、「能動的学修（アクティブ・ラーニング）への転換が必要である」とされており、既に多くの大学でアクティブ・ラーニングの導入が行われている。

その一方でアクティブ・ラーニングに対する批判もある⁽²⁾。文献⁽²⁾には、正しく理解していない者が集まって相談して導き出した解は、しばしば誤ったものになり、教育として問題のある事例が紹介されている。この事例の 1 つに、小学校の授業で「遠い星から届く光が地球に届くまで時間がかかる」ということを学んだ後、「太陽は」という問に対して、「星と太陽は別」であるため、太陽の光は瞬時に届くと主張した児童の主張がその場の「解」になった例が紹介されている。文献⁽²⁾では、読解力の向上が必要であるとされており、それはその通りである。しかし、読解力が不足する場合や問題解決のための知識が不足する場合、「解」が正しいかどうかを容易に検証できる問題であれば、アクティブ・ラーニングの成功する可能性がある。

この「星」の例の場合、小学生には精密な天体観測が不可能である。しかし、題材をもっと身近なものにして、やってみると誤りであることが分かるような題材とすることにより、誤りに気づき、改

善されていくことが期待できる。つまり、正しい知識に基づかない誤った解を導き出してそれを真の解と誤解しないようにするためには、その解が正しいかどうか容易に検証できる題材が適している。

「解」が正しいかどうかを検証できる方法として、アクティブラーニング手法の中でも PBL (Problem Based Learning 問題解決型学習/Project Based Learning 課題解決型学習) が注目すべき手法である。この手法であれば、問題が解決しない場合、その「解」は誤ったものであるか、少なくとも「解」のどこかに不足している部分があるということがすぐに分かる^(註1)。さらに、PBLの中でも学生の学習意欲を高めつつ、かつ研究・学習成果を社会に還元可能な産学連携型の PBL は有益である^(註3)。

通常大学等で行われている産学連携 PBL の対象の多くは、第 2、3 次産業であり、第 1 次産業が産学連携 PBL の対象になる例は少ない。工業高等専門学校の専攻科の PBL としてや農業系教員のもとでの卒業研究や特別研究としてエンジニアリング教育が行われている例があるものの^(註4)、第 1 次産業を対象とした産学連携 PBL は、十分普及しているとは言い難い。

一方、地方都市では、大規模な製造業は大企業の地方工場であるため、その工場独自に決定できることや新規の開発案件が少なく、大企業の地方工場での産業 PBL は、学生向け PBL として適していない。また、企業側としても地方工場での産業 PBL 受け入れが困難な場合が多い。しかし、地方都市及びその周辺では、農業が主要産業である。したがって、農業における産業 PBL は、地方都市に立地する大学にとっては重要な PBL のテーマとなりうる。

本稿では、農業における産業 PBL として、スマート農業化に向けた AI の利用検討のために機械学習により農作物の等級を判定する「AI 等級判別システムの構築」を試みた。そして、この結果をもとに学生らの PBL 教材が構築できると考えられる。

2. AI 等級判別システム

2.1 AI の普及

近年、報道等で毎日のように AI が取り上げられているような AI ブームとなっている。これまでも少なくとも 2 度 AI ブームがあったが、今回の AI ブームは、これまでのブームと異なり、AI を専門とする人以外への技術の普及が急速に進んでいる。これは、以前の AI ブームの時よりも高性能なコンピュータが安価に広く普及していることも影響しているが、より大きく影響を与えているのは、AI 技術が広く公開されたためである。

例えば、Google が開発した TensorFlow ライブラリは、ソースコードが無償で公開されている。以前の AI ブームでは、このように技術の根幹が無償で公開されるということではなかった。しかし、Google は、AI の真の価値は AI の「エンジン」ではなく、AI を賢くするのに必要な「データ」であると^(註5)し、エンジン部分を公開した。さらに、今回の AI ブームの根幹となっている「機械学習」は、プログラミングによって問題解決するのではなく、データを与えると問題解決の手段が得られるため、

データさえあれば実現が比較的容易である。

データさえあれば AI の実現が容易であるということは、低コストで AI を導入できる可能性が高く、このことが非 AI 専門家でも AI を活用したシステムを構築できることに寄与している。

また、AI が低コストで導入できれば、これまで AI のみならず情報技術の導入ができていなかった用途にも技術を導入し、生産性を向上させることができる。したがって、地域の活性化や地域の産業に AI を用いた情報技術の成果が導入できる可能性が高いと考えられ、「地域活性化」や「地域産業の振興」のための地域産業への AI 導入は重要である。

2.2 地方都市の産業

地方都市や農村地域などの経済基盤は主に農作物の生産活動であり、地域再生を可能にするための研究は喫緊の課題である⁽⁶⁾。

農業には労働環境・作業内容が「きつい (Kitsui)」「汚い (Kitanai)」「危険 (Kiken)」であることを意味する 3K というイメージがあり、若者の就労が進んでいない。この解決策として考えられるのは、スマート農業である⁽⁷⁾。スマート農業により、農業の工業化が進めば、農業に希望を持つことができるため、次世代の農業従事者の育成⁽⁸⁾が可能かもしれない。

一方、スマート農業推進のためには、IT 技術、とりわけ AI 関連技術が重要であると考えられる。AI 関連技術は、その影響・効果が大きいのに比して導入が容易であり、スマート農業に導入する ICT 関連技術の中心となると思われる。

2.3 AI 農業の PBL への導入

データ駆動型の AI 技術は現在広く普及する段階に至っており、その技術を利用するだけであれば、大学初年次の学生でも十分可能である。これは、先に述べたように Google 等が TensorFlow 等のライブラリにより、AI エンジンを無償で公開しているためである。また、これらの AI エンジン、習得が容易なプログラミング言語によって簡単に使用することができる。

一方、地方都市及びその周辺には農家が多く、PBL のためのフィールドワークを受け入れてくれる農家が多く確保できる。この点も地方都市において PBL のためのフィールドワークに農業が適している理由である。

2.4 AI 等級判別システムの PBL への導入

農業において重要な作業が作物の選別である。農作物の品質の安定化と向上による競争力の強化が重要である⁽⁹⁾。特に、その中でも農作物の選別が労力のかかる作業となっている。この分野で、近年 AI による画像認識によって農作物を判別する事例が報告された⁽¹⁰⁾。この報告では、キュウリの選別システムの構築例が紹介されている。また、この選別システムは報告の著者個人で開発されており、大きな資金が必要なく、農業に AI 技術を導入できることが示されている。

上記のように、農作物の選別システムに関しては、既に先行事例がある。このため、文献⁽¹⁰⁾と同様な手法でその地域の実情に合わせた作物の選別システムを作るとは、初年度の学生らにも理解が容易で、教材として適している。

一方、AI 等級判別システムによる PBL の案を福知山市農林商工部産業振興課パワーオンネット事務局(以後、福知山市パワーオンネットとする)に提示したところ、実験可能な農園を容易に確保することができた。このことから、地方都市においては農業が主要産業であり、PBL を実施することが容易であることが分かる。さらに、農作物の画像データには、著作権や人権等に関する制限がなく、画像を自由に実験に使うことができる。このことも農作物の選別が教材として優れている点の 1 つである。

今回は、上記のように AI による等級判別システムが PBL に適していると考え、それを試行実験により確認することとした。

3. PBL のための試行実験 1(万願寺とうがらしの選別)

3.1 万願寺とうがらしの選別

万願寺とうがらしは、ブランド京野菜として登録されている競争力の高い農作物である。ブランドの維持のためには、作物の選別に慎重さが要求される。このため、PBL 教材の候補として万願寺とうがらしを選定した。

万願寺とうがらしの実験では、合同会社丹波の里ひぐち農園の協力を得て、万願寺とうがらしの実験用画像を取得することができた。取得した画像は、とうがらし 326 本分で、1 本のとうがらしを上面と側面の 2 箇所から撮影した。2 箇所からの撮影としたのは、事前にとうがらしの付け根の部分(エボと呼ばれている)が選別に関係するという資料の提供を受けていたためである。また、画像とは別に 326 本すべてのとうがらしについて、人手の選別結果を入手し、これを学習用教師データ及び評価用データの正解として用いた。

3.2 実験装置

実際に装置を製作した場合のコストダウンを想定し、撮影には安価な書画撮影用カメラ 2 台と小型コンピュータ(Raspberry Pi3)を用いた(図 1)。カメラは小型コンピュータから制御され、撮影した画像は小型コンピュータ内のマイクロ SD カードに格納される。撮影操作は、小型コンピュータに接続されたマウスとキーボードを用いて行う。カメラは、小型コンピュータと USB で接続されている。カメラからのデータは、小型コンピュータに接続されたマイクロ SD カード上に保存する。

撮影用のプログラムには、学生らに改良させることを考え、習得が比較的容易で AI 関係のライブラリを容易に利用可能な Python 言語を用いた。図 2 は実験風景である。図 2 では万願寺とうがらしが 2 本撮影台の上にあるが、これは撮影条件を決定するための予備撮影時であったためで、実際に判

別に使う画像では、万願寺とうがらしを1本ずつ撮影している。なお、今回は試行実験ということで、撮影対象を撮影台に置く作業は人手で行った。




図1 実験装置概要



図2 実験風景

3.3 AI による選別方法

今回用いた選別方法は、ニューラルネットワークを用いた機械学習法である。今回の試行実験では、畳込みニューラルネットワーク (CNN: Convolutional Neural Network) を用いた。ニューラルネットワークの作成には、Keras ライブラリを使用した。図 3 は、そのソースコードの主要部分である。判別結果の個数は、nClass 変数に格納されているとして、このプログラムが実行される。プログラム実行の結果、nClass 変数に格納された個数の群に判別するニューラルネットワークモデルが構築される。その後、教師データを与え、ニューラルネットワークモデルを作成する。

今回の実験に使ったニューラルネットワークは、この CNN のみであるが、今後判別率を上げるためにニューラルネットワークのモデルを最適化する必要があると思われる。この部分も、学生の PBL として適しているであろう。

3.4 判別結果の判定方法

判別結果は、取得した画像をランダムに教師用の画像と判別実験用の画像の 2 群に分け、教師用の画像によりニューラルネットワークを構築し、そのニューラルネットワークで判別実験用の画像を判定し、その判定の正答率でニューラルネットワークを評価した。教師データは、全体のデータの 7 割とし、残りの 3 割で判定率を確認する。教師データと試行データはランダムに分割した。分割するプログラムには、scikit-learn のライブラリを用いた。

3.5 選別実験の結果

秀、優、良、それ以外の 4 値で判別すると、65.3%程度の判別率であった。一方、秀、優の組とそれ以外だと判別率は 93~96%と実用に耐える判別率となった(表 1)。これは、秀と優の判別が難しいことに起因していると考えられる。

秀と優の大きな決定要因となるのは、とうがらしの大きさととうがらしの先端の形状である。大きさが秀のサイズであっても、とうがらしの先がピーマン果(尖っておらず、ピーマンのような形になっている)であった場合は、1 段階級を落とす(秀のサイズ・形なら優にする)という判定基準がある。このため、先端の形状を判断する必要がある。

図 4 は秀と判定された万願寺とうがらしの例である。長さが 13cm~23cm で①適季収穫のもの、②色艶良好で品種固有の形状を有するもの、③曲がりの軽微なものが秀と判定される。一方、大きさが秀の範囲であっても、とうがらしの先端が尖っておらず、ピーマンのような形状になっているものはピーマン果と呼ばれており、1 ランク格下げされる(図 5)。

```

# モデルの作成
model = Sequential()

# モデルにレイヤーを積み上げていく
model.add(Conv2D(32, (3, 3), padding='same',
                 input_shape=x_train.shape[1:]))
model.add(Activation('relu'))
model.add(Conv2D(32, (3, 3)))
model.add(Activation('relu'))
model.add(MaxPooling2D(pool_size=(2, 2)))
model.add(Dropout(0.25))

model.add(Conv2D(64, (3, 3), padding='same'))
model.add(Activation('relu'))
model.add(Conv2D(64, (3, 3)))
model.add(Activation('relu'))
model.add(MaxPooling2D(pool_size=(2, 2)))
model.add(Dropout(0.25))

model.add(Flatten())
model.add(Dense(512))
model.add(Activation('relu'))
model.add(Dropout(0.5))
model.add(Dense(nClass))      # nClass 個の群に判別する
model.add(Activation('softmax'))

# 訓練プロセスの定義
model.compile(loss='categorical_crossentropy',
              optimizer='sgd',
              metrics=['accuracy'])
    
```

図 3 判別に用いたニューラルネットワークの定義

表 1 判別率の実験結果

分類条件	判別率
(優,秀)それ以外	93~96%
(秀,優)と良とそれ以外	85~88%
秀と優と良とそれ以外	65.3%
良とそれ以下	75.7%



図4 秀判定の例

13cm 以上で曲がりがなく、先端が尖っている



図5 ピーマン果の例

先が尖っておらずピーマンのような形状となっている。

今回はとうがらしの付け根(エボ)部分の画像は撮影しているものの、先端の詳細な画像は撮影していなかった。試みとして、取得された画像に含まれているとうがらしの先端部分の画像のみを切り出し、その判別を試みた。その結果、60.3%の判別率でピーマン果を判別できた。さらに、ピーマン果の写真を詳しく調べると、秀と判定されているものの中にもピーマン果のように見えるものが含まれていたため、写真上でピーマン果と見えるものをピーマン果として判別を試みた。すると、ピーマン果の判別率は、83%~86%程度となった。このように、画像判別により、秀の中にピーマン果が含まれているとした方が判別率の上がる場合のあることが分かった。

この理由として考えられることは、優と秀の差は、人間が見ても判断が付きにくい上に、農協で再度選別することが前提にあり、農協からは、品数を揃えるために判定をゆるくするように説明されているからのようである。実際に、出荷実績の伝票を確認すると、農協での選別により平均で10%弱が秀から優に変更されていた。

秀と優以外との判別の容易さを確認するため、秀優の組とそれ以外に分けた2値で判別した。この場合の判別率は、93%~96%であった。このことから、大まかな外形の判断については、AI判別が十分実用になることが分かる(表1)。また、秀優の組と良とそれ以外の3値に判別した場合、85%~88%の判別率となり、良とそれ以下のみのデータから良とそれ以下を判別した場合、判別率は76%程度となった。この判別率の低下の原因は、良より下のランクのサンプルが全体の1割程度の33サンプルと少なかったため、ニューラルネットワークの学習が進まなかったためであると考えられる。

良未満のとうがらしは出荷されないため、できるだけ良い作物を作るように配慮されていることから良未満を入手することは困難であり、良未満のサンプルの入手が課題である。また、とうがらしの付け根の部分に飛び出したものは「エリマキ」と言われ、良と判断される(図6)。今回はこのエリマキのサンプルも不足していたことも、十分な判別率を得ることができなかった原因であると思われる。

一方、本来ならばとうがらしの先端部分だけのカメラを用意すべきであったと思われる。今回は、事前に入手していたランク判定表にとうがらしの付け根(エボ)部分の説明が書かれていたので、反対側のエボの部分は撮影していたが、結果的にこの部分は上面からのカメラの画像で判別可能で、判別結果には大きく影響しなかった。

また、農協での判定は、とうがらしの生産量に応じて変動している可能性があるため、その点を含めた選別方法の検討が必要であることが分かった。

3.6 PBL への万願寺とうがらし判別の導入

今回の試行実験により、①判別率の向上と②対象作物の十分な理解、③農地への理解が必要であることが分かった。判別率の向上は技術的課題であり、これはこの解決法を考えることでPBLとして一定の効果があると思われる。また、判別率の向上のためには、対象作物の性質を良く理解する必要があり、この点は地域の産品の理解に繋がり、PBLとして効果的であろう。



図6 「エリマキ」の例

一方、今回の試行実験により実際に農地に行き実験することは、各種の困難が伴うことが分かった。泥などで機器が誤動作しないための工夫等はあらかじめ想定していたが、今回の試行実験では蚊に悩まされた。大量の蚊が飛来し、実験が困難になる場面もあった。このようなことは、実際にフィールドワークをしてみないと経験できないことである。もし、学生らがこのような体験をしたならば、学生らはその対応法を考えることが必要になり、良い経験となると思われる。

上記のことから、今回の試行実験のようなことを学生らに PBL として経験させることは、「地域のことを理解し、地域の課題の解決法を考える」ための教育として適しているといえる。

4. PBL のための試行実験 2(クリの選別)

4.1 クリ選別への取り組み

前章で述べた万願寺とうがらしの実験に関する記事が福知山市パワーオンネットの Web サイトに掲載されると、クリ農家からクリの選別に AI が利用できないかという問い合わせがあった。このため、クリの選別にも取り組むこととした。Web サイトに掲載されたただですぐに問い合わせがあるということは、地域の農業の高度化に対する関心が高く、学生の PBL としても適した題材であることを示していると考えられる。

4.2 クリの選別の基準

試行実験では、福知山市夜久野町のクリ農家にて実験用画像を取得した。このクリ農家は、非常に高品質なクリを生産する農家であり、その出荷基準は想定していたより厳しいものであった。

虫食いの跡は非常に小さいものでも虫食いと判定されていた。非常に小さい虫食いの跡で、農家では「虫がかじっただけかもしれない」という極小の傷でも、出荷基準に満たないとのことであった。実際に、この非常に小さな傷のあるクリを切断し、クリの中身を確認したところ、虫の混入は認められなかった。

また、臭いでも判断するとのことで、クリの先端から出てくる臭いによって、外観では判断できない実炭そ病の検出をしているとのことであった。外観で判断できない初期の実炭そ病であっても、クリの味が大幅に低下するとのことであった。

クリの大きさは4L、3L、2L、L、それ以外の5ランクに分けられる。各サイズのクリの例を図7に示す。



図7 クリのサイズの例

左から L,2L,3L,4L である。

4.3 現状のクリの選別法

現状のクリの大きさ判別は、穴の空いた金属板でふるいにかける方法でなされる(図8)。ふるいに固定する金属板の穴の大きさが各種サイズ分用意されており、この穴に通ったものはより下の大きさの階級に分類される(図9)。ふるいの穴に通るかどうかで大きさを判断しているため、クリの形状によっては、穴に通っても上位の階級であることも起こりうる。これは、クリの形が扁平しており、クリの短辺がふるいの穴の直径よりも小さいが、クリの長辺が長い場合に起こりうる。このため、実際には、目視によって大きそうなクリを見つけ、クリの重さを測定し、その結果によって階級を上げる処理が発生する。その他、選別後に虫食いによる傷や臭いの判定によって出荷基準内かどうか判定される。




図8 選別用のふるい

この「ふるい」にクリを入れ、図右側のふるいの取っ手を持ち、揺ることによりクリを選別する。



図9 ふるいの中の金属板

穴の大きさが選別段階の数だけ用意されており、この金属板を変更することにより各種サイズのクリに選別できる。

4.4 AI によるクリ選別実験

当初は、虫食いの選別を検討したが、虫食いが撮影できるまで詳細なクリの画像を取得するための方法が困難であったため、クリの外形による判別を今回の実験の目標に設定した。

実験に用いた装置は、万願寺とうがらしとほぼ同一(図1)であるが、側面からの撮影は外形の判断には必要無いため、今回は使用していない。したがって、上面からの撮影のみとなる。

判別に用いたニューラルネットワーク(図3)やそれを使った判別率の判定方法は万願寺とうがらしと同一である。

クリの画像 326 枚を取得した。クリのランクは 4L、3L、2L、L、それ以外の 5 群に判別した。実験の結果、外形でのクリの選別は十分実用できる判別精度を得ることができ、約 90%の判別率であった。

クリの判別には、大きさが 3L ランクのものであっても、クリの質量が大きいと 4L にするということであるが、今回は質量の測定をしていない。それでも、90%程度の判別率であった。これは、選別枠で 3L の大きさの穴を通る場合でも、重さで 4L と判別される場合はクリの長辺が長く、この長辺の長さは外形で判断できるため、結果として外形による判断だけで正しく 3L と 4L を判別できたものと考えられる。

試行実験の結果、簡易な実験でも 90%程度の判別率が得られたことから、外形を用いたクリの大きさ判別に AI 技術を導入することは適していることが分かった。

4.5 クリ判別における問題点と PBL 教材としての適性

今回、外形のみの判定を試みて、その実用性を確認することができた。しかし、クリの選別には虫食いと実炭そ病の判定がある。虫食い穴は非常に小さく、発見が難しい。撮影時に虫食い跡が撮影できていれば、判別可能だと思われるが、撮影が非常に困難であり、今回は虫食いの判別を断念した。虫食いが判断できる程度に詳細な画像を撮影するためには、クリを物理的に移動させながら撮影するような方法を採用する必要があり、この問題解決には時間がかかる。

一方、実炭そ病については、病状が進行すると目視による検出が可能であるが、この農家のクリは高級品であるため、病状が進行する前の段階で実炭そ病の検出が必要である。この検出のためには、臭いによる判定が必要で、実炭そ病のクリは、クリの先端から独特な臭いが出るようである。この作業には苦労が多く、長時間続けることができないそうである。したがって、臭いの検出の機械化は、労力の削減につながるが、現在のところ十分な反応速度で臭いを検出できるセンサーが無く、今後の課題である。軟 X 線での撮影によるクリ選別の報告⁽¹⁾があることから、別のセンサーを用いる方法も検討しなければならない。

このように、試行実験によってクリ選別における課題が分かってきた。このような課題は、実際にフィールドに出ることによってしか発見できないものである。さらに、短期間の試行実験により課題

を複数見つけられるということは、問題解決することで学ぶという PBL の特性に合致し、学生らの PBL 教材として適していると考えられる。

5. 今後の発展と PBL 教材としての可能性

5.1 認識率の向上

今回の実験では、万願寺とうがらしの等級判別において、認識率を十分高めることができなかった。この原因には、先に述べた通り規格外品のサンプルの少ないことや、撮影のノウハウの不足が考えられる。そして、この問題の解決には試行錯誤が必要である。試行錯誤することは、学生らに考える機会を提供できるため、農作物の選別は、PBL 課題に適していると考えられる。

5.2 AI 以外の知識の必要性

画像が取得できてからの AI の判別能力の向上は見込めるが、画像を取得するためには、撮影対象を適切にハンドリングする必要がある。この部分は今回人手で対応したが、適切なハンドリングのためには、それに応じた機械を作成する必要がある。文献⁽¹⁰⁾では、キュウリ判別用のベルトコンベア式の機械が紹介されており、これはほぼ 1 人で実現されている。他の機器の設計経験者が 1 人で対処できる程度の課題であれば、初年次の学生でも数人がかりでの課題としては適切な課題の規模であると思われる。また、AI を動作させるためには、物理的な処理が必要であるということを学生らに理解させ、現状の AI の限界を知る教材としても適している。

一方、機械を作成するには、設備投資が必要となる。したがって、装置を製作するために設備投資と収益のトレードオフを考えることが必要となり、実際に装置を製作するためには技術的な面以外の検討も必要になる。したがって、AI をうまく使用できるような機械やシステムを検討・製作することは、問題解決法を学ぶための課題として使用できると考えられる。

5.3 設備メーカーとの共同開発の検討

福知山市パワーオンネットとの協議により、設備メーカーとクリ選別システムの可能性を検討した。検討の結果、図 10 のようなシステムとした場合の価格を検討することとした。

このシステムは、パーツフィーダーによりクリを取り出し、ロードセルで質量を計測した後、ベルトコンベアにて搬送し、画像による判定で階級を分け、階級ごとの箱にクリを投入する。画像はクリの両面から撮影し、画像認識時に外観ですぐに判断できるような異常は検出する。ロードセルは小型のマイコンによって制御し、画像認識には Raspberry Pi3 程度のコンピュータ、全体の制御にはメンテナンスの容易さを勘案し、市販のシーケンサを用いる。

このような選別システムを実用化する場合、クリ選別の画像認識部分だけでなく、制御装置のプログラミングやシステムの取りまとめなどの作業が必要となる。また、通常の製造設備等に必要な技術

的要素（画像の取得、画像の前処理、画像認識、センサーからのアナログ値取得、センサー信号の処理、コンピュータ間の通信）を含んでいる。このため、学生らにこれらの作業をさせることにより、実践的な教育効果が得られるものと思われる。




図 10 クリ選別システムの構想図

6. まとめ

今回は、PBL 教育のために農業への AI 導入がテーマとして妥当であるか検討するための試行実験を行った。実験では、万願寺とうがらしとクリの画像による選別を試みた。実験の結果、簡単なプログラムで作物の外形に基づき選別することは容易であり、学生らの PBL に適した題材であることが分かった。

一方、判別率の向上には学生らが解決できそうなレベルでの課題があり、この課題解決を PBL 教材として用いることができると考えられる。また、クリの実炭そ病への対応など農業分野には大きな課題が残されており、このような課題は、上級生が取り組むのに適しているのではないかとと思われる。

《参考文献》

- (1) 文部科学省, 新たな未来を築くための大学教育の質的転換に向けて～生涯学び続け、主体的に考える力を育成する大学へ～ (答申). 2019年1月31日閲覧 (2012)
http://www.mext.go.jp/b_menu/shingi/chukyo/chukyo0/toushin/1325047.htm
- (2) 新井紀子, AI VS. 教科書が読めない子どもたち, 東洋経済新報社, pp.234-239 (2018)
- (3) 榎大輔, 大学教育における産学連携型 PBL 実施手法の研究—初年次教育への導入事例とその評価—, 商経学叢, Vol.64, No.3, pp. 345 – 361 (2018)
- (4) 吉澤宣之, et. al., 我が国農業の将来を高専での工学教育が支える-国立高専の校長・教務主事の先生方にお尋ねしました。そのアンケート結果です。-, 大分工業高等専門学校紀要, Vol.53, pp.63-70, (2016)
- (5) グーグルは、なぜ AI エンジンをオープンソース化したのか?, WIRED.jp, 2015年12月5日, 2018年1月31日閲覧
<https://wired.jp/2015/12/05/google-open-sourcing-tensorflow-shows-ai-future/>
- (6) 山中守, 青果物価格の季節変動に関する経済分析: 「自然」と「経済」の「葛藤と共生」: 地域再生の経済学(X), 尚綱大学研究紀要. A, 人文・社会科学編, Vol.48, pp.51-70 (2016)
- (7) 渡邊智之, スマート農業のすすめ, 産業開発機構株式会社, pp.67-86 (2018)
- (8) 吉澤宣之, et. al., 我が国の農業の将来を高専の工学教育で支える-Future of Japan's Agriculture supported by Engineering Education in KOSEN-, 大分工業高等専門学校紀要, Vol. 52, pp. 41-51 (2015)
- (9) 渡邊智之, スマート農業のすすめ, 産業開発機構株式会社, pp.103-116 (2018)
- (10) 小池誠, キュウリ選別コンピュータ, インターフェース, 2017年6月号, pp.23-52 (2017)
- (11) 三輪精博, 小林 一, 加藤 章, 軟 X 線による栗の被害果の判別について, 岐阜大学農学部研究報告, Vol.53, pp.115-126 (1988)

《注》

- (1) 特定の問題を解決する解を見出したとしても、それが真に正しいことを保証することはできないが、少なくともその問題を解決できるという点で評価することが出来る。