優秀賞 賞金 10 万円

MIKAN

（まじでいいかんじにあまくなる）

鳥羽商船専門高等学校

MIKAN

MAJIDE II KANJINI AMAKU NARU

報告書

令和元年 11 月

鳥羽商船高等専門学校
制御情報工学科

４年　加藤　慶
４年　中北　創太
４年　中谷　瑞希
３年　山本　青奈
３年　米田　有美子

要旨

三重県紀南地域は、農業産出額の大半をミカンの生産に依存している地域です。[1] しかし、日本国内の農業は高齢化や後継者不足が深刻な問題となっています。中には、成果を上げている若手農家も存在しますが、農作業は長年の経験や知識、高度な技術を要するため、技術継承が進んでいません。そのため、高品質ミカンの安定生産が困難になってきています。

スマートフォンアプリ「MIKAN」では、高品質なミカンを生産するために重要な水分ストレスを、学習済みAIを用いて推定することで、高品質なミカンの安定生産を実現します。これにより、新規就農者のように農業経験が少ない方でも容易に水分ストレスを判別することができます。さらに、従来の水分ストレス測定時にかかっていた労力を軽減することができます。実証実験では、水分ストレスを測定することが可能であることが実証できました。これにより熟練農業者の経験や勘に頼らない水分ストレスの判別が可能になります。今後は、アプリの精度を向上させることで幅広い作物に対応出来るアプリを目指します。

目次

１．背景・・・・・・・・・・・・・・・・・・・・・・・・・・・・1

２．目的・・・・・・・・・・・・・・・・・・・・・・・・・・・・2

３．プロジェクトの概要・・・・・・・・・・・・・・・・・・・・・・3

４．最終目標・・・・・・・・・・・・・・・・・・・・・・・・・・4

５．システム

５．１　概要・・・・・・・・・・・・・・・・・・・・・・・・・5

５．２　システム詳細・・・・・・・・・・・・・・・・・・・・・6

５．２．１　水分ストレス推定アプリ　・・・・・・・・・・・7

５．２．２　基礎的事項・・・・・・・・・・・・・・・・・・10

５．２．３　AI による水分ストレス判定・・・・・・・・・13

６．実験

６．１　学習用データの収集・整理・・・・・・・・・・・・・・18

６．２　空撮時間帯別の精度比較・・・・・・・・・・・・・・・20

６．３　実験方法１（９分割画像による事前学習・検証）・・21

６．３．１　９分割画像による事前学習・・・・・・・・・・21

６．３．２　検証およびモデルの評価・・・・・・・・・・・22

６．４　実験方法２（回転画像による事前学習・検証）・・・23

６．４．１　回転画像による事前学習・・・・・・・・・・・23
６．４．２　検証およびモデルの評価・・・・・・・・・・・24
６．４．３　精度比較と考察・・・・・・・・・・・・・・・24
６．４．４　回転画像による学習２(分類モデルの作成)・・25
６．４．５　検証およびモデルの評価・・・・・・・・・・・26
６．４．６　考察・・・・・・・・・・・・・・・・・・・・27
６．５　実際のアプリを使って実証・・・・・・・・・・・・・28
６．５．１　実験方法・・・・・・・・・・・・・・・・・・28
６．５．２　実験結果・・・・・・・・・・・・・・・・・・28
６．５．３　考察・・・・・・・・・・・・・・・・・・・・29
７．まとめ・・・・・・・・・・・・・・・・・・・・・・・・30
８．今後の展望・・・・・・・・・・・・・・・・・・・・・・31
９．感想・・・・・・・・・・・・・・・・・・・・・・・・・32
１０．参考文献・・・・・・・・・・・・・・・・・・・・・・35

１．背景

三重県紀南地域は紀伊半島先端部に位置しており、年平均気温 16.4℃、年間降水量 2,800mm の温暖多雨といった気候から、極早生ミカン・早生ミカン・ポンカン・甘夏・不知火・カラ・サマーフレッシュなど四季を通じ、いろいろなミカンが栽培されています。この地域のミカン生産は三重県内の 65%を占めており、農業産出額の大半をミカンの生産に依存しています。また、極早生ミカンが特産品として良く知られており、出荷時期が早いことから他の産地品種に対して高い競争力を持っています。

しかしながら、紀南地域の83%が森林で耕地は4.5%しかなく、地理的条件の不利性による過疎化や高齢化に伴う労働力不足、後継者不足が深刻な問題となっています。中には、成果を上げている若手農家も存在しますが、農作業は長年の経験や知識を要するため、技術継承が進んでいません。特に、ミカンの品質に直結する水やり作業は高度な技術を必要とします。

一般的に、ミカンは乾燥による水分ストレスを与えることで糖含量が増加します。植物が葉内に水分を保持している力の強さをLeaf Water Potential (LWP)といい、水分ストレスを示す指針として用いられます。LWPが最適な値であるとき、適度な水分ストレスが与えられた状態であり、糖度の高いミカンを生産することができます。従来は、採取した葉を圧力容器にかけて測定する水ポテンシャル測定装置を用いてLWPの測定が行われていました。しかし、高価であるとともに樹体から葉を手作業で一本一本取り機器にかける必要があるため手間がかかるといった問題があります。更には、葉内が十分な湿潤状態であるときをLWPの初期値とするため、蒸散が少ない早朝の3時から5時の間に測定を行わなければなりません。このように既存する機器でのLWP測定は、非常に大きな労務負担であり、農家の方には普及していません。実際の水やり作業の多くは、農家の方の経験に基づいた目視によって行われています。

これらの理由から、LWP の推定を容易化することで農作業における省力・軽労化が進められるとともに、若手農家でも高品質ミカンの安定生産を実現する技術が待ち望まれています。

２．目的

「MIKAN」の目的は、経験の少ない若手農家の方でも高品質で高糖度な極早生ミカンの安定生産を可能とすることです。AI を用いて LWP の推定を容易に行えるスマートフォンアプリを開発することで、熟練農業者の経験や勘を再現し、新規就農者でも高品質なミカンの安定生産が実現できます。

また従来の LWP 測定時にかかる農作業の省力・軽労化が可能になるとともに、若手農家でも短期間で水やり作業技術の向上・高度化を図ることができ、熟練者と同等の水やり作業が可能になります。

３.プロジェクトの概要

１.背景で述べたように、LWP を測定する水ポテンシャル装置は非常に高価であるとともに、測定に人手や手間がかかるといった問題があり、農家の方には普及していません。そこで、私たちは AI とスマートフォンアプリを組み合わせることで、若手農家でも「高品質極早生ミカンの安定生産」を実現することができるシステムの開発を目的とします。本システムの動作は以下に示します。

本システム動作の流れ

１.スマートフォンカメラで撮影された果樹全体の画像を AI に送信
２.学習済み AI による LWP の推定
３.「ストレス値が高い」、「丁度良いストレス値」、「ストレス値が低い」の 3 段階で診断結果が転送

４．最終目標

３.プロジェクトの概要で示した「高品質な極早生ミカンの安定生産」を実現するために、「AI にミカン葉の学習させること」、「スマートフォンアプリの開発をすること」を最終目標とします。

➢ AI によるミカン葉の学習

紀南果樹研究所で撮影された樹体の画像 1000 枚を用いて、撮影日に LWP 測定装置で測定した LWP 値と樹体番号を照らし合わせ、高ストレス、中ストレス、低ストレス、ストレスなしの４種にクラス分けする。

画像を分割・回転させ、更に画像枚数を増やし、これらを AI に学習させる。

➢ スマートフォンアプリの開発

カメラで撮影またはアルバムから選択された画像を学習済み AI に送信し、返却された結果を画面に表示する。また、木ごとの結果を管理し、グラフを表示する機能を実装する。

5．システム

5．１　概要

「MIKAN」のシステム概要を以下の図に示します(図 5.1.1)。

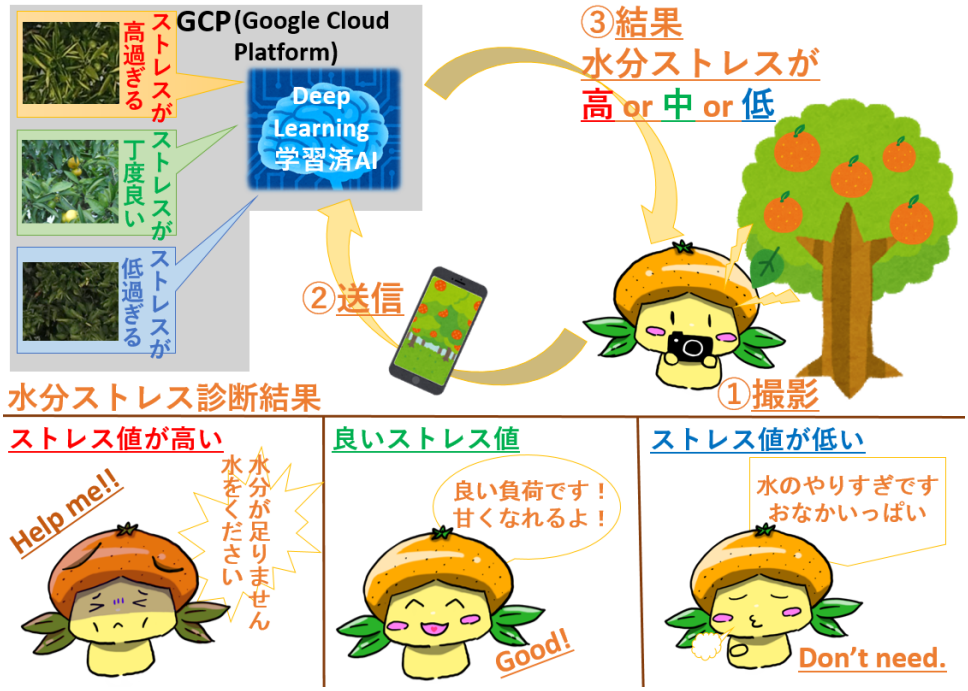

図 5.1.1 システム概要図

「MIKAN」は果樹の写真を撮るだけで、葉の様子からミカン果樹の水分ストレスを知ることができます。これは、熟練した果樹農家の方が、水分ストレスの推定を葉の様子を見て判断することにヒントを得ています。扱い方は非常にシンプルです。「MIKAN」はスマートフォンアプリですので、スマートフォンのカメラを使って撮影された果樹の写真を、クラウド上にある AI に送信し、果樹がどの程度の LWP であるかを推定します。学習済 AI は、あらかじめ果樹の画像と、当該果樹の LWP を組とした大量の教師データを用いて学習を済ませています。それにより、果樹の様子から、どのくらいの LWP があるかを判断し、結果を返すことができます。診断結果として表示されるのは、「ストレス値が高い」、「丁度良いストレス値」、「ストレス値が低い」の 3 段階です。基本的には、「丁度良いストレス値」をキープできれば、高糖度のミカンを安定して収穫できることがわかっています。これらの知見は、豊富な知識・経験を持っている地元営農指導員の方から、ご教示いただいたものです。

５．２　システム詳細

「MIKAN」は撮影された果樹の画像を学習済み AI に送信し、学習済み AI が判定した結果を受け取る必要があります。そこで私達は Google Cloud Platform(GCP)という Google が提供しているクラウドコンピューティングサービスを使用しました。「MIKAN」では画像を分類するための機械学習モデルをトレーニングする必要があります。そのため、独自に定義したラベルに従って画像を分類するよう機械学習モデルをトレーニングすることが出来る AutoML Vision を使用しました。また、GCP 上で Python の関数を実行することが出来る Cloud Functions を使用しました。このようなシステム構成とした理由としては、iOS アプリから AutoML Vision に直接認証をすることができないためです。そのため、Cloud Functions を使用し、本機能を実装します。Cloud Functions を用いることで、無駄なサーバーを必要とせず、アプリの代わりに認証を行うことが出来ます。また、セキュリティ的にもセキュアになります（図 5.2.1）。

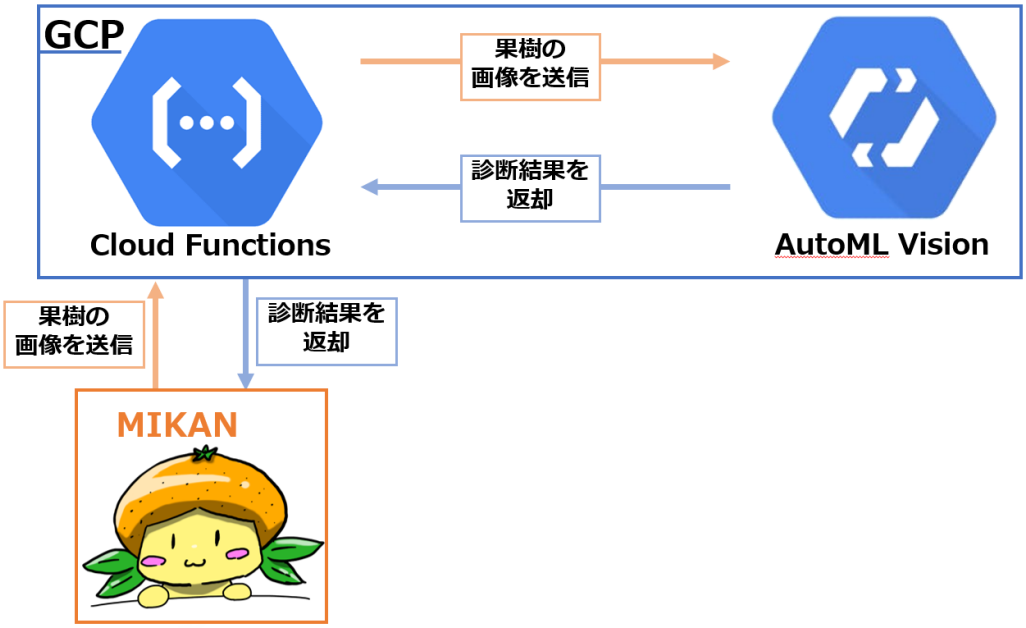

図 5.2.1 システム詳細

５．２．１　水分ストレス推定アプリ

➢ 開発環境

開発環境と開発言語を以下の表に示します(表 5.2.1.1)。

表 5.2.1.1 開発環境と開発言語

開発環境	開発言語
Xcode 11.0	Swift 5.0
	Python 3.7

➢ クラウド環境

クラウド環境を以下の表に示します(表 5.2.1.2)。

表 5.2.1.2 クラウド環境

クラウド環境
Google Cloud Platform ● AutoML Vision ● Cloud Functions

➢ 操作方法

操作方法は以下の通りです。シンプルで使いやすい UI となっています。

① メニュー画面から木を選択する画面に移動します（図 5.2.1.1）。

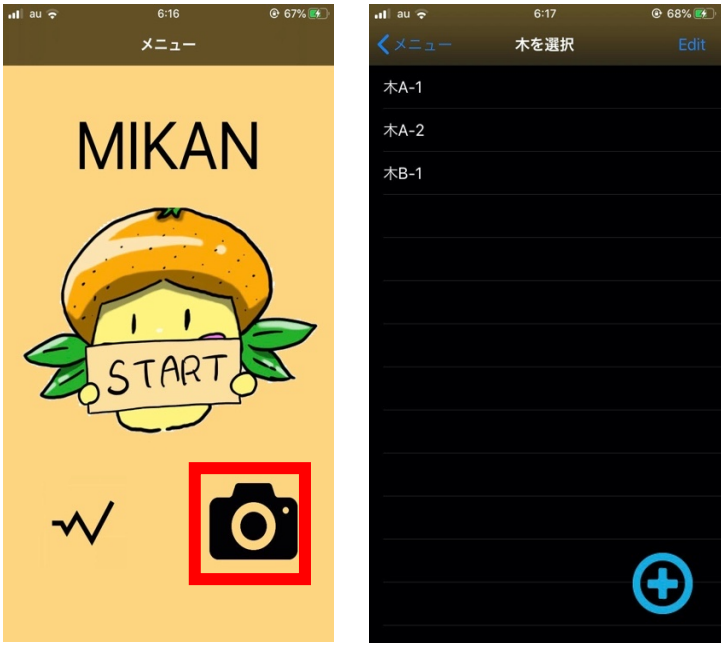

図 5.2.1.1 木を選択する画面

② カメラで撮影またはアルバムから選択された果樹の画像の水分ストレスの結果を表示します（図 5.2.1.2）。

図 5.2.1.2 測定結果

③　メニュー画面からグラフ画面に移動します（図 5.2.1.3）。

図 5.2.1.3　グラフ画面

５．２．２　基礎的事項

➢ Deep Learning（深層学習）

「ディープラーニング（Deep Learning）」は、「深層学習」とも呼ばれる機械学習手法の1つであり、入力されたデータからクラス分類や回帰を行う手法です。そもそも機械学習とは、人工知能の一分野として研究が始まり「ロボットやコンピュータなどの機械が、経験（学習）から行動するためのパラメータを自動的に獲得する方法」として定義されています。そして、現在はより広義となり、「データの中で、みえているものからみえていないものを予測する方法」ともいえます。機械学習は、自然言語処理や画像認識、バイオインフォマティクス、さらにはリスク予測など、工学のみならず経済学や心理学などの多分野で活躍しています。

機械学習は統計的学習として、大量のデータを用いて学習を行います。予測正解値となる教師信号を同時に与え、データとその教師信号をもとに、データに共通する情報や、特徴的な情報（特徴量）から予測する手段を獲得します。特徴量は、色やエッジなど人が定義した抽出方法により抽出された情報です。特徴量の抽出には、教師信号を用いずにデータから自動的に特徴量を抽出する方法もあります。教師信号を用いる学習を教師あり学習、教師信号を用いない学習を教師なし学習といいます。ディープラーニングには、両方の方法があり、教師信号があるなしに関わらず大量のデータを用いて、与えられたデータのクラス分類や回帰を行うネットワークを学習します。ネットワークは、何層もの階層構造になっており、人がものを認識する際の構造に似ています。

➢ 畳み込みニュートラルネットワーク

ニュートラルネットワークのような誤差逆伝播法による学習を取り入れた方法が、畳み込みニュートラルネットワーク（CNN: Convolutional Neural Network）と呼ばれます。CNN は人の視覚野にある受容野をモデル化した構造となっており、入力層（input layer）、畳み込み層（convolution layer）、プーリング層（pooling layer）、全結合層（fully connected layer）、出力層（output layer）から構成されています。畳み込み層とプーリング層は複数回繰り返して深い層を形成し、その後の全結合層も同様に何層か続きます。

➢ TensorFlow Hub

TensorFlow Hub[3]は 2018 年 Google が公開したフレームワークであり、ImageNet[4]などの画像データを使用し学習させた学習済みモデルが用意されています。その学習済みモデルを使用することで 1 からモデルを作る必要がなくなるといったメリットがあります。今回は TensorFlow Hub で用意されている Inception-ResNet-v2[5]という学習済みモデルを水分ストレスの判別に応用しました。

➢ 転移学習（Transfer Learning）

転移学習[6]（図 5.2.2.1）は、ある領域で学習させたモデルを別の領域に適応させる技術のことです。1 から学習させるのは多くの時間を必要とします。そこで ImageNet などの画像データを使用し学習させた学習の仕方（特徴を抽出する能力）を知っている学習済みモデルを使うことで、より早く特徴を抽出することができます。これにより少ない画像枚数でも学習を行うことが可能になります。

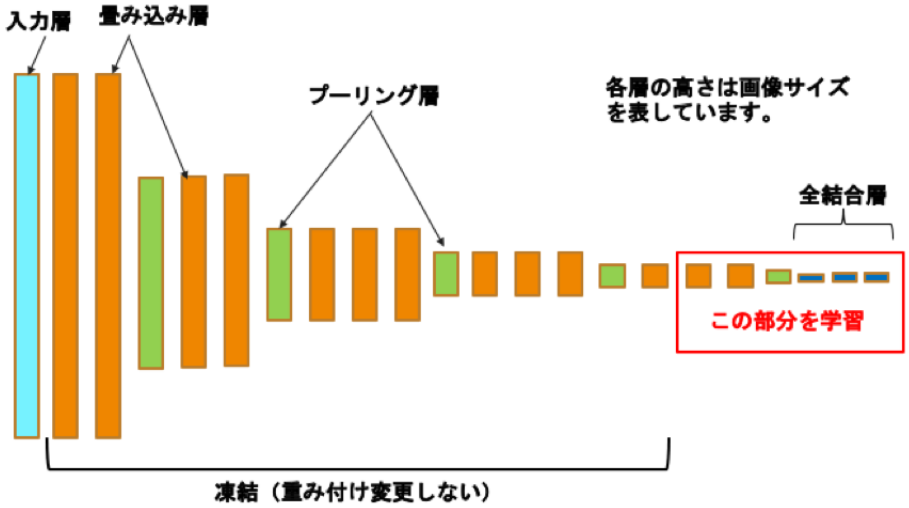

図 5.2.2.1 転移学習

➢ 学習の流れ

学習の流れ[7]を以下の図に示します(図 5.2.2.2)。今回の学習にはラベルを付けた画像を使用する教師あり学習を用いました。

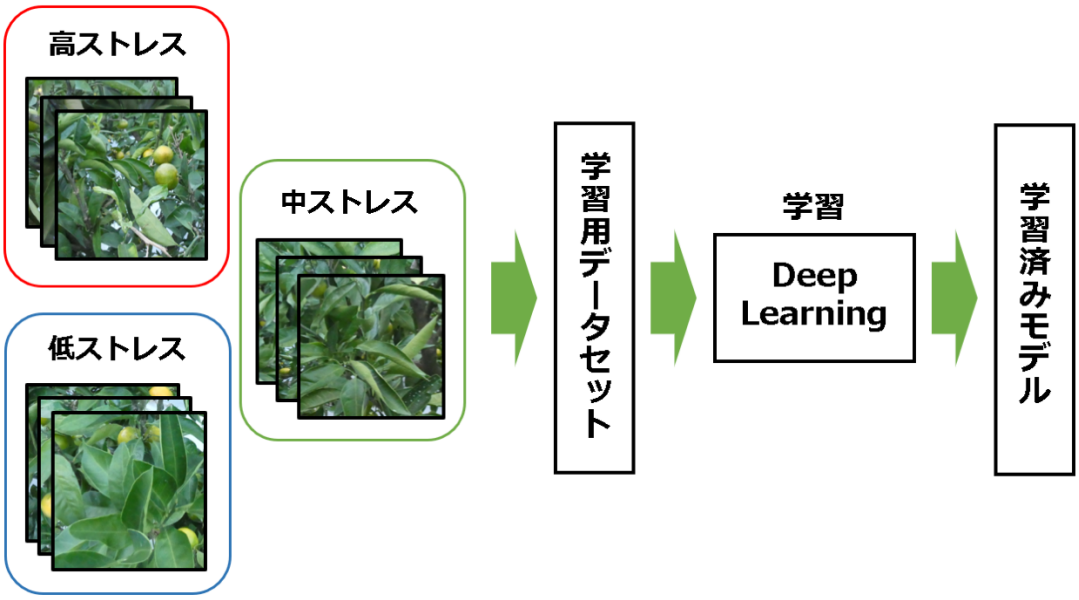

図 5.2.2.2 学習の流れ

５．２．３　AI による水分ストレス判定

➢ 水ポテンシャルとは

水ポテンシャル[8]とは植物が葉に水分を保持している力の強さのことです。「水を引き付ける力」であるので負圧で表されます(単位はメガパスカル MPa)。水ポテンシャルは以下の式から求めることができます(式 1)。ϕ_{leaf} は葉の水ポテンシャル、ϕ_p 葉の圧ポテンシャル、ϕ_π 葉の浸透ポテンシャルです。

$$\phi_{leaf} = \phi_p + \phi_\pi \quad (式 1)$$

(吸水力 = 膨圧 － 浸透圧)

➢ 水分ストレスと水ポテンシャル関係

水分ストレスは水ポテンシャル（LWP: Leaf Water Potential）の値で定量的に測定することができます。水分ストレスと水ポテンシャルの関係を以下の図に示します(図 5.2.2.3)。水ポテンシャルの値が大きくなるほど高ストレス、小さくなるほど低ストレスです。

図 5.2.2.3 水分ストレスと水ポテンシャルの関係

➢ プレッシャーチャンバー法

本研究のデータセットのクラス分けにはプレッシャーチャンバー法[9]（図5.2.2.4）で測定した水ポテンシャルの値を用います。機器にセットした葉を窒素ガスで加圧し、葉柄から水が逆流したときの圧力がその樹体の水ポテンシャルの値となります。

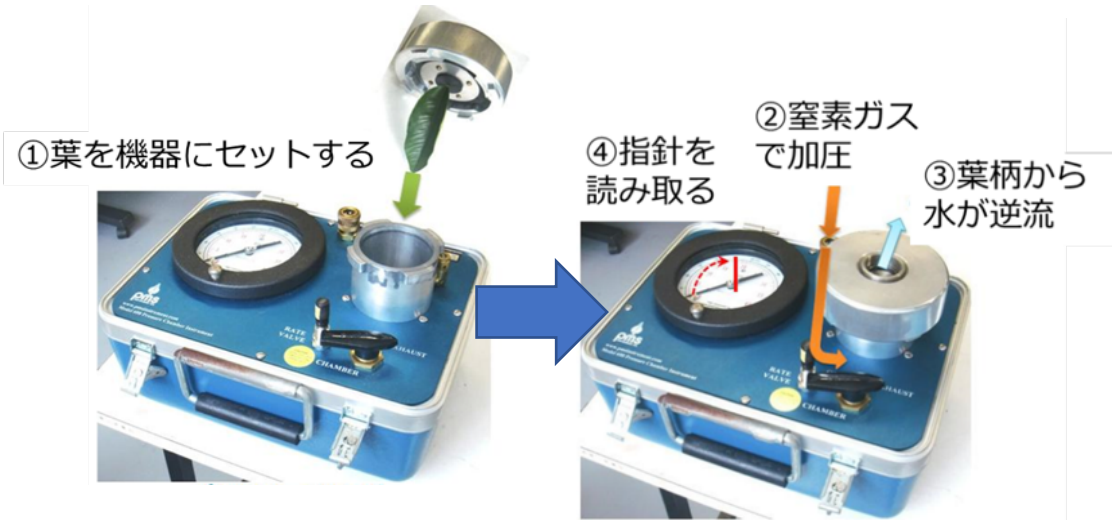

図 5.2.2.4 プレッシャーチャンバー法

➢ マルチ・ドリップ方式

三重県農業研究所の紀南果樹研究室で研究対象とされている果樹や当該地域で栽培されている果樹の多くは、畝にマルチを被せることで雨水の影響を受けず果樹に与える水の量を調節することが可能なマルチ・ドリップ方式[10]（図5.2.2.5）を用いて栽培されています。これにより樹体ごとに水分ストレスをコントロールしています。紀南地域は、他の産地にくらべ10月の降水量が多く本方式を用いない場合、果実の糖度を高くすることが難しいため、紀南地域では本方式を用いることが、高品質果実の安定生産に必要不可欠な技術となっています。

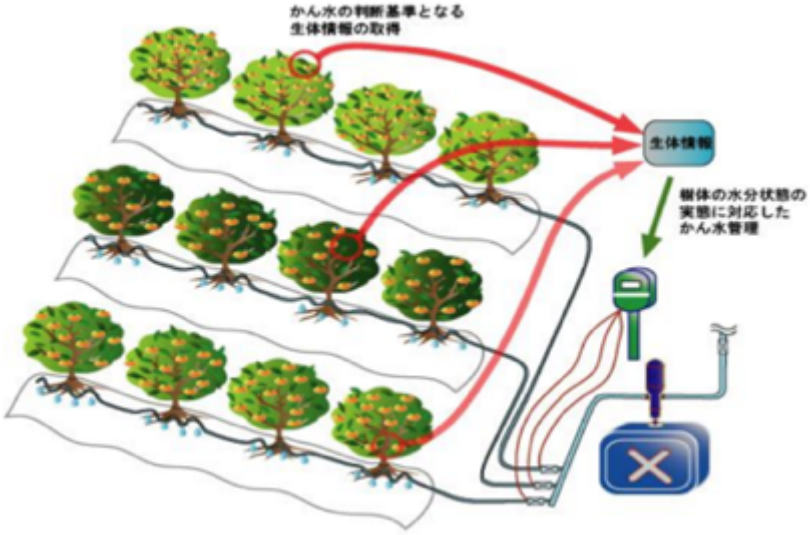

図5.2.2.5 マルチ・ドリップ方式

➢ 過学習（Over-fitting）

機械学習において、あるデータに過度に対応した状態を指します。[11]

つまり、本来学習するべき特徴以外の訓練データだけに存在する特徴だけに対応してしまい、未知のデータに対して高い学習精度を得ることができない状態のことです。過学習を避けることは，機械学習の重大な課題となっています。

➢ 正解率（Accuracy）

全体のデータ(表 5.2.2.1)の中で、正しく分類できたデータ TP(True Positive)と正しく分類できなかったデータ TN（True Negative）がどれだけあるかという割合のことです。正解率が高いほど精度が高い良いモデルということになります。正解率は以下の式から求めることができます。(式 2)

表 5.2.2.1 全体のデータ

分類結果＼正解ラベル	正	負
正	True Positive（TP）	False Positive（FP）
負	False Negative（FN）	True Negative（TN）

$$\text{Accuracy} = \frac{TP+TN}{TP+FP+TN+FN} \qquad (式\ 2)$$

➢ 適合率（Precision）

全体のデータ（表 5.2.2.1）の中で、正（Positive）と分類されたデータの中で実際に正（Positive）であったデータ数の割合のことです。この値が高ければ高いほど、間違った分類が少ないということになります。適合率は以下の式から求めることができます(式 3)。

$$\text{Precision} = \frac{TP}{TP+FP} \quad (\text{式 } 3)$$

➢ 再現率（Recall）

全体のデータ（表 5.2.2.1）の中で、正（Positive）データの中で、実際に正（Positive）だと分類されたデータの数の割合のことです。この値が高ければ高いほど、取りこぼしなく正しく分類しているということになります。再現率は以下の式から求めることができます(式 4)。

$$\text{Recall} = \frac{TP}{TP+FN} \quad (\text{式 } 4)$$

➢ F 値

適合率と再現率は一般的にどちらかが高くなるとどちらかが低くなるようなトレードオフ関係にあることから、適合率と再現率だけではモデルを評価することが難しいです。よって、F 値によりモデルの総合的な性能をはかる必要があります。F 値が高いモデルは、適合率と再現率のバランスが取れているモデルということになります。F 値は以下の式から求めることができます(式 5)。

$$\text{F-mearure} = \frac{2Recall \cdot Precision}{Recall+Precision} \quad (\text{式 } 5)$$

６． 実験

６． １　学習用データの収集・整理

平成 30 年度に収集した学習用画像データ数（18 時に撮影した空撮画像）は、高ストレス画像 1008 枚、中・低ストレス画像 12600 枚となりました。（表 6.1.1）。平成 30 年度 7 月 26,27 日および 8 月 6,7 日に、紀南果樹研究所試験園地においてドローンによる樹体空撮を実施し、学習用画像データを収集しました（図 6.1.1）。雨の影響により高ストレス画像が 14 枚と学習に十分な枚数でなかったため、画像の 9 分割および回転を行いました（図 6.1.2）。回転は 9 分割した画像それぞれに行いました。回転角度は 0, 45, 90, 135, 180, 225, 270, 315 度としました。クラス分けに関しては、プレッシャーチャンバー法により樹体の水ポテンシャルを測定し、測定値と樹体番号を照らし合わせることでクラス分けを行いました(図 6.1.3)。

表 6.1.1 学習用画像データ数（平成 30 年度）

分類ラベル	収集データ数	9 分割後のデータ数	9 分割および回転後のデータ数
高ストレス画像	14 枚	126 枚	1008 枚
中・低ストレス画像	175 枚	1575 枚	12600 枚

図 6.1.1 学習用画像データ収集の流れ

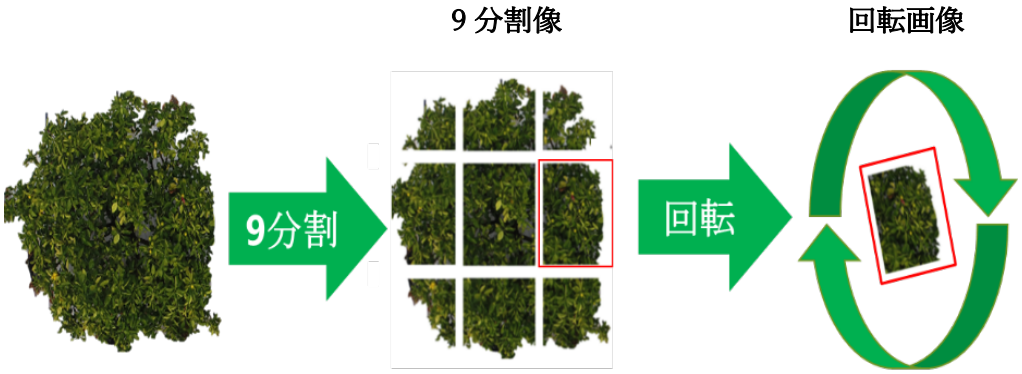

図 6. 1. 2 画像の 9 分割および回転

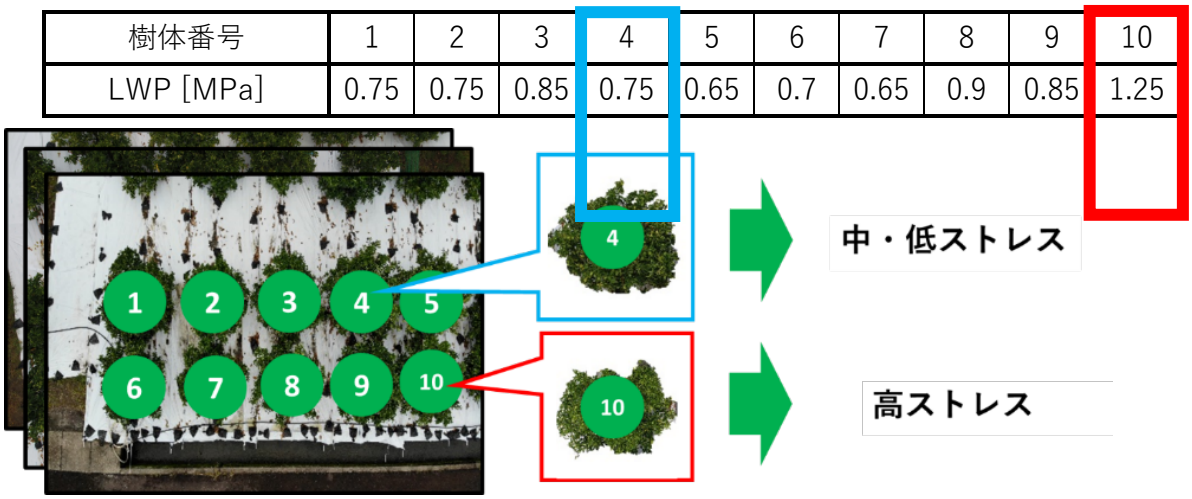

樹体番号	1	2	3	4	5	6	7	8	9	10
LWP [MPa]	0.75	0.75	0.85	0.75	0.65	0.7	0.65	0.9	0.85	1.25

図 6. 1. 3 画像のクラス分けの流れ

６．２　空撮時間帯別の精度比較

空撮時間帯別の精度比較では、水分ストレス推定に適した空撮時間帯の検証を行いました。検証では、12 時，15 時，18 時の 3 つの空撮時間帯の比較を行いました。各時間帯、事前学習には各クラス 9 分割および回転させた画像を 500 枚使用し、検証には各クラス 9 分割および回転させた画像を 100 枚使用しました。各時間帯の検証における正解率を以下の表に示しました(表 6.2.1)。結果より正解率が最も高かった 18 時の空撮画像が最も早朝に測定した水ポテンシャルの値と相関関係があると言えます。よって以下の実験では 18 時の空撮画像を使用します。12 時の画像が最も正解率が低い理由として、光合成による蒸散により樹体の見た目が変わらないまま水ポテンシャルの値が上昇することが考えられます。

表 6.2.1 各空撮時間帯の検証における正解率の比較

12 時の空撮画像	15 時の空撮画像	18 時の空撮画像
50.5%	86.0%	89.5%

６．３　実験方法１
（９分割画像による事前学習・検証）

６．３．１　９分割画像による事前学習
（分類モデルの作成）

9 分割による事前学習には、各クラス 9 分割した画像を 90 枚使用した（表 6.3.1.1）事前学習において、正解率 88%を達成しました（図 6.3.1.1）。学習に偏りが出ないようにするため、教師データの枚数を各クラスで統一しました。

表 6.3.1.1 教師データ数

分類ラベル	教師データ数 （9 分割画像）
高ストレス画像	90 枚
中・低ストレス画像	90 枚

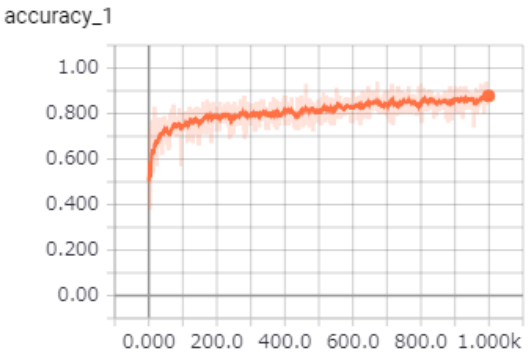

図 6.3.1.1 事前学習の正解率

６．３．２　検証およびモデルの評価

検証には各クラス 9 分割を行った画像を 18 枚使用しました（表 6.3.2.1）。検証における分類結果を以下の表に示します(表 6.3.2.2)。検証の結果、正解率が 77.8%でした。本検証では、事前学習に使用していない画像を用いて分類を行う交差検証方式を採用しました。検証の結果より、このモデルは十分な汎化能力（未知のデータに対応する力）があるとは言えず、事前学習に用いる画像枚数が少なく十分に学習ができていないことが原因だと考えられます。モデルの評価に必要な正解率, 適合率, 再現率, F 値の値を以下の表に示します(表 6.3.2.3)。

表 6.3.2.1 検証用データ数

分類ラベル	検証用データ数
高ストレス画像	18 枚
中・低ストレス画像	18 枚

表 6.3.2.2 検証における分類結果

分類結果 ＼ 正解ラベル	高ストレス	中・低ストレス
高ストレス	16 枚（TP）	6 枚（FP）
中・低ストレス	2 枚（FN）	12 枚（TN）

表 6.3.2.3 モデルの評価

正解率(Accuracy)	適合率(Precision)	再現率(Recall)	F 値(Fmeasure)
77.8%	72.7%	88.9%	80.0%

６．４　実験方法２
（回転画像による事前学習・検証）

６．４．１　回転画像による学習１
（分類モデルの作成）

回転画像による事前学習には、各クラス 9 分割および回転を行った画像を 500 枚使用した（表 6.4.1.1）事前学習において、正解率 97%を達成しました（図 6.4.1.1）。学習に偏りが出ないようにするため，教師データの枚数を各クラスで統一しました。

表 6.4.1.1 教師データ数

分類ラベル	教師データ数（回転画像）
高ストレス画像	500 枚
中・低ストレス画像	500 枚

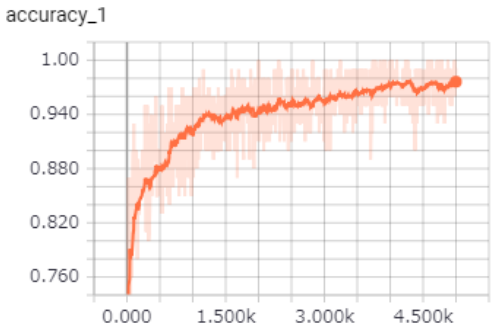

図 6.4.1.1 事前学習の正解率

６．４．２ 検証およびモデルの評価

検証には各クラス 9 分割および回転を行った画像を 100 枚使用しました（表 6.4.2.1）。検証における分類結果を表 6.4.2.2 に示します。検証の結果、正解率 89.5%を達成しました。本検証では、事前学習に使用していない画像を用いて分類を行う交差検証方式を採用しました。これはモデルの汎化能力を検証するためであり、検証における正解率が 89.5%と十分な汎化能力を示した結果となりました。モデルの評価に必要な正解率，適合率，再現率，F 値の値を表 6.4.2.3 に示します。

表 6.4.2.1 検証用データ数

分類ラベル	検証用データ数
高ストレス画像	100 枚
中・低ストレス画像	100 枚

表 6.4.2.2 検証における分類結果

分類結果 ＼ 正解ラベル	高ストレス	中・低ストレス
高ストレス	92 枚（TP）	13 枚（FP）
中・低ストレス	8 枚（FN）	87 枚（TN）

表 6.4.2.3 モデルの評価

正解率(Accuracy)	適合率(Precision)	再現率(Recall)	F 値(Fmeasure)
89.5%	87.6%	92.0%	89.7%

６．４．３ 精度比較と考察

実験方法１と実験方法２の正解率の比較より、9 分割画像を使用した学習に比べて、回転により画像枚数を増やした学習の方が良い精度になりました。これは事前学習に使用する画像枚数を増やしたことで精度が向上したと考えられます。よって、今後さらに空撮を行い事前学習に用いる画像枚数を増やすことで精度を上げることができると考えられます。

６．４．４　回転画像による学習２（分類モデルの作成）

回転画像による事前学習には、各クラス 9 分割および回転を行った画像を 500 枚使用した（表 6.4.4.1）事前学習において、正解率 97%を達成しました（図 6.4.4.1）。学習に偏りが出ないようにするため、教師データの枚数を各クラスで統一しました。

表 6.4.4.1 教師データ数

分類ラベル	教師データ数（回転画像）
高ストレス画像	500 枚
中・低ストレス画像	500 枚

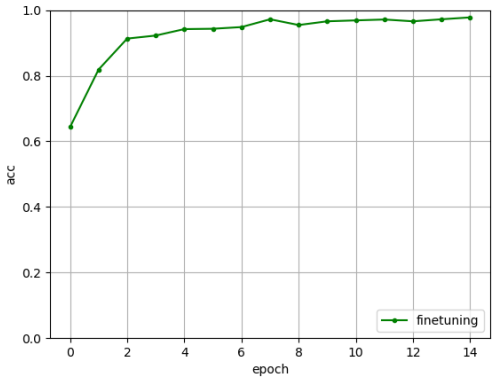

図 6.4.4.1 事前学習の正解率

６．４．５　検証およびモデルの評価

検証には各クラス 9 分割および回転を行った画像を 100 枚使用しました（表 6.4.5.1）。検証における分類結果を以下の表に示します(表 6.4.5.2)。検証の結果、正解率 95.5%を達成しました。本検証では、事前学習に使用していない画像を用いて分類を行う交差検証方式を採用しました。これはモデルの汎化能力を検証するためであり、検証における正解率が 95.287%と十分な汎化能力を示した結果となりました。モデルの評価に必要な、正解率、適合率、再現率、F 値の値を以下の表に示します(表 6.4.5.3)。

表 6.4.5.1 検証用データ数

分類ラベル	検証用データ数
高ストレス画像	100 枚
中・低ストレス画像	100 枚

表 6.4.5.2 検証における分類結果

分類結果 ＼ 正解ラベル	高ストレス	中・低ストレス
高ストレス	91 枚（TP）	0 枚（FP）
中・低ストレス	9 枚（FN）	100 枚（TN）

表 6.4.5.3 モデルの評価

正解率(Accuracy)	適合率(Precision)	再現率(Recall)	F 値(Fmeasure)
95.5%	100%	91%	95.287%

６．４．６ 考察

検証結果より、以前の学習モデルよりも高確率での分類が可能であることが分かりました。しかし、検証における分類結果(表 6.4.5.2)からも分かりますが、現在の分類モデルは中・低ストレスは 100 枚すべてを分類することができたのに対し、高ストレスの画像からはそのうちの 9 枚を中・低ストレスであると判断してしまっています。このように偏った結果が出た原因として、今回の学習モデルの教師データや、検証で利用した画像は 2018 年のもので、撮影日には雨が降っていたことが原因となって誤分類に繋がった可能性があります。そのため、再度 2019 年 10 月に画像の追加の撮影を行いました。その撮影した画像は晴れた日に撮影したものなので、雨による影響がありません。また、データ量も 2018 年のときより多く用意することができたため、2019 年のデータを利用する事で今回よりも偏りのない結果を出すことができるのではないかと考えます。また、先ほど述べたようにデータ量が昨年よりも豊富にあるため、分類クラスを増やしても高い精度を保てるのではないかと考えられます。

また、別の原因として考えられるのは過学習を起こしてしまった可能性です。過学習が起こる一般的な原因は、教師データの不足や、モデルが問題に対して複雑すぎることなどが挙げられます。したがって、過学習を起こさないように学習を行えば、精度の高い学習モデルが完成すると考えられます。

６．５　実際のアプリを使って実証

６．５．１　実験方法

三重県南牟婁郡御浜町志原の紀南果樹研究室にて撮影されたミカンの樹体の画像 1000 枚を用意し、スマートフォンアプリ「MIKAN」を用いて実験します。9 月 25 日と 10 月 2 日の 2 日間のミカンの樹体を用意します。そして、その樹体の全体を撮影した画像をクラウド上にある AI へ送信します。送信した画像を学習済み AI に LWP がどの程度か判定させ、それから得られた結果を元に樹体の撮影日に LWP 測定表量で測定した LWP 値と樹体番号を照らし合わせながら「ストレス値が高い」、「丁度良いストレス値」、「ストレス値が低い」の 3 クラスに分け測定します。

６．５．２　実験結果

実験 1 の方法より、LWP の値が高い果樹を撮影すると、アプリに「ストレス値が高い」(図 6.5.2.1)と表示されました。その他に LWP の値が低い果樹、中ぐらいの果樹と続けて測定していくと、多少の誤差はあるものの、想定通り、「ストレス値が低い」(図 6.5.2.2)「丁度良いストレス」と、診断結果を出すことが確認できました。

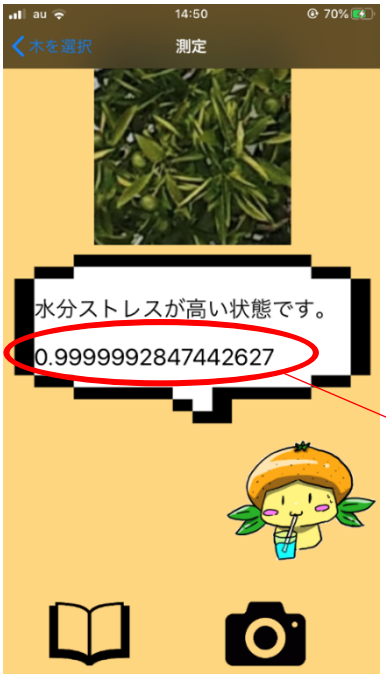

図 6.5.2.1

図 6.5.2.2

６．５．３　考察

この実証実験の結果により、スマートフォンのみを用いてLWPを測定することができ、3段階の水分ストレス状態を表示することができました。それによって、ミカンの水分が多いか少ないかをすぐに知ることができます。従来の方法と比較すると樹体から採取した葉を圧力容器にかけて測定する水ポテンシャル装置は高価で手間が掛かるので農家の方にとって負担が大きく、扱うことが困難でした。しかし「MIKAN」を使うことによってLWPをスマートフォンのアプリで容易に測定することができ、作業の効率化や、コストパフォーマンスを上げることができました。したがって、若手農家の方でも高品質なミカンを作ることができ、後継者不足の問題を解決に近づけることができます。またクラウドのAIに多くの画像を学習させることによってより精度の高いアプリに出来ると考えられます。

７．まとめ

「MIKAN」でLWPを容易に測定できるようになったことで、新規就農者のように経験が少なくても、熟練者の勘や経験に頼らずに水分ストレスを判別することができるようになり、高糖度な極早生ミカンの安定生産に貢献することが出来ました。更には、従来のLWP測定時の労務負担が軽減され、農作業における省力・軽労化が実現できました。

また、アプリ開発を行ったことで既存の製品と比べ大幅にコスト削減することが出来ました。今後は、実証実験を重ねることで高品質で高糖度な極早生ミカンの安定生産を実証していきたいと思います。

８．今後の展望

今後の展望は、LWP をより正確に測定するために、AI に学習させるミカン葉の画像枚数を増やしアプリの精度向上を目指します。

更には、三重県熊野市の若手果樹農家の方々を対象にして農業の現場で実証実験を行うことで、幅広い農園・果樹に対応するアプリを目指します。実際の現場で使用してもらいながらアプリ開発を進めることで、さらなる品質・生産の向上を実現し、地域活性化の貢献に努めます。既に来年度からの使用に向けて、熊野市の営農指導員の方々と打ち合わせ等をすすめています。

９．感想

私は今回で、気象観測機器コンテストへの参加が2回目となります。毎年、作品制作過程において、学ぶことが沢山あります。

今回は、初めてチームをまとめる立場を経験させていただき、リーダーの苦労やチームをまとめる難しさを実感しました。そして、最も大切だと思ったのは、報連相と呼ばれる「報告・連絡・相談」です。これらは、仕事を円滑に進めるうえで重要な役割だけでなく、チーム内でコミュニケーションをとる一つの手段でもあると思いました。また、普段から雑談などをすることで、報連相をしやすいチームの雰囲気作りも大切であると学びました。また、今回はあらかじめ担当を分担したことで、責任感を持つことができ自主的に仕事を進めることができたと思います。

ミカンの栽培について詳しく調べていくうえで、ミカンは乾燥によるストレスで糖度が大きく変わってしまうとても繊細な果実であるにも関わらず、既存のLWP測定機器は高く、人手や手間を要するという現状に、とても驚きました。高糖度なミカンの生産は長年の知識や経験だけでなく各農家独自の工夫や苦労が詰まっているのだなと改めて農業の難しさを実感しました。そんな農家の方に「MIKAN」を使っていただくことで、これまでの農作業の労務負担軽減に少しでも貢献できたらいいなと思います。

コンテストでは、是非とも、最終選考の場で審査員の方々や会場にいらっしゃる方々の目を引くようなプレゼンテーションを行いたいと思います。
そして、コンテストだけで終わるのではなく、改良を続け、実際の農業の現場で使用していただけるような精度の高いアプリにしていきたいと思います。

制御情報工学科４年　中谷瑞希

私はアプリ開発を担当しました。私は今回の気象観測機器コンテストが初めて参加するコンテストで、どう進めていけば良いかわからずとても不安でした。ですが、メンバーとのコミュニケーションをとるだけでなく、先輩方にも助言をいただくことで、円滑に進めていくことができました。

また、Swift を触ることも初めてで、理解をするためにとても多くの時間を費やしましたが、あらかじめ担当を分担したことで、早く作業を始めることが出来ました。

このコンテストを通じて Swift の知識だけでなく、ミカンの知識や農家の方

の苦労や努力も改めて知ることが出来ました。そんな農家の方に「MIKAN」を少しでも早く使っていただけるように今後もアプリの改良を続け、より見やすく使いやすいものにしていきます。
　そして、この経験を活かし、ミカンだけでなく、別の果物や野菜でも使えるアプリを作成し、他の農家の方にも貢献できるようにしていきたいと思います。是非とも、最終選考の場で審査員の方々や会場にいらっしゃる方々に「MIKAN」を披露することができればと思います。

制御情報工学科４年　加藤慶

　私は、主に加藤と共にアプリ開発を担当しました。当初、本年のコンテストに参加する予定ではありませんでしたが、「MIKAN」のシステム開発において技術的な課題が数多くあり、途中からチームの一員として活動する運びとなりました。
　「MIKAN」の開発に際しては、実際のミカン農家様に多大なご協力をいただいております。我々自身も農園に出向いて活動することで、農作業の大変さや農家の方の想いを肌で感じ、チーム一同、我々の技術が少しでも負担軽減や効率化に貢献することを願い、開発を進めてきました。
　最終選考の場においては、会場の皆様に成果を余すところなく伝えられるよう準備して参ります。
　また、今回のコンテスト参加に留まることなく、今後も農家の方からフィードバックを頂き、より良いシステムとなるよう改良を進めていきます。
　農業においては、僅かな気象の変化が成果に大きな影響を及ぼします。今回の成果に甘んじることなく、より正確なデータを提供できるようなシステムへと発展させたいです。

制御情報工学科４年　中北創太

　私はコンテスト自体初めての参加で、不慣れなことが多々あり、この先しっかりできるだろうかとても心配していました。はじめはわからないことが多く、先輩方に質問をし、アドバイスをもらいながら作業を進めていました。今回の気象観測機器コンテストで一つの作品を作ることにたくさんの時間と人との連携が必須なのだと改めて感じました。今回は先輩に頼ってしまうことが多

く、自分だけでは出来ないこともありました。
　今回のMIKANの開発に携わって、ミカン農家の方がどれだけ苦労しながら作っているのかということを再認識できる良い機会となりました。このアプリを農家の方々が使用して頂くことによってミカンを作る際の負担を少しでも軽減し、効率的な農作業を実現できることに貢献することができ、とても光栄なことだと思います。さらに今回の経験を元にたくさんのことを学ぶことができ、この貴重な経験を通してこれからも頑張っていきたいです。

制御情報工学科3年　米田有美子

　私は、気象観測機器コンテストに限らず、コンテストに参加することは、今回が初めてのことでした。初めのうちは何をしたらいいのか、何もわかりませんでした。しかし、頼りになる先輩方から指示をいただき、少しではありますが、今回の作品に貢献できたのではないかと思います。ただ、やはり先輩方に頼りきりになってしまったとも思います。今は後輩という立場にある程度甘えられますが、遅くとも来年には自分が手を引く側に回ります。そうなったときに自分が、自分の先輩方のようにしっかりと支えることが出来るのだろうかと、今から気が気ではありませんが、自分にできる限り頑張ろうと思っています。
　今回の作品の作成において私は、ミカン農家に限らず、若い人手が不足しているという現状や、それにも関わらず、体力が必要になるような作業の多い世界だということを再認識しました。その大変な作業に少しでも力添えのできる作品であると思います。私はこのコンテストでの作品に関わることで得た経験は、とても貴重なものであったと思います。

制御情報工学科３年　山本青奈

１０．参考文献

[1] “平成 28 年度三重県農業産出額”,http://www.maff.go.jp/tokai/tokei/attach/pdf/mini-12.pdf,参照 Feb.14,2019.

[2] OPTiM Cloud IoT OS, “AI とは？AI（人工知能）と Deep Learning（深層学習）を簡単に説明”, https://www.optim.cloud/blog/ai/ai-deeplearning/ ,参照 Feb.14,2019.

[3] TensorFlow, “TensorFlow Hub”, https://www.tensorflow.org/hub/, Feb.14,2019.

[4] IMAGENET, http://www.image-net.org/, 参照 Feb.14,2019.

[5] Qiita, “[Survey]Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning”,https://qiita.com/supersaiakujin/items/106a553ab720d04d6ea6, 参照 Feb.14,2019.

[6] フリエン,“転移学習とは | 機械学習とディープラーニングとの関係性と必要スキル”, https://furien.jp/columns/344/, 参照 Feb.14,2019.

[7] LEAPMIND BLOG,“ディープラーニング（Deep Learning）とは？【入門編】”, https://leapmind.io/blog/2017/06/16/, 参照 Feb.14,2019

[8] 石田 厚（2008）「生態学Ｉ」, http://www.ecology.kyoto-u.ac.jp/~atto/PDF/EcoI_04_Ishida.pdf, 参照 Feb.14,2019.

[9] 和歌山県果樹試験場,“灌水情報” , http://www.mikan.gr.jp/ftes/kansuiweb4/lwp.html#%E6%B8%AC%E5%AE%9A, 参照 Feb.14,2019.

[10] 森永 邦久（2012）「高品質カンキツ生産のためのマルドリ方式の開発」, http://www.agri-renkei.jp/docs/20120314seminar_morinaga.pdf, 参照 Feb.14,2019.

[11] AI 研究所(2018) 「AI が学習しすぎる？「過学習」問題とそれを抑制する方法」, https://ai-kenkyujo.com/2018/10/16/kagakushu/, 参照 Nov.1,2019

優秀賞 賞金 10 万円

自律型水位観測アレイ

「長崎オリオンネット」

長崎県立宇久高等学校

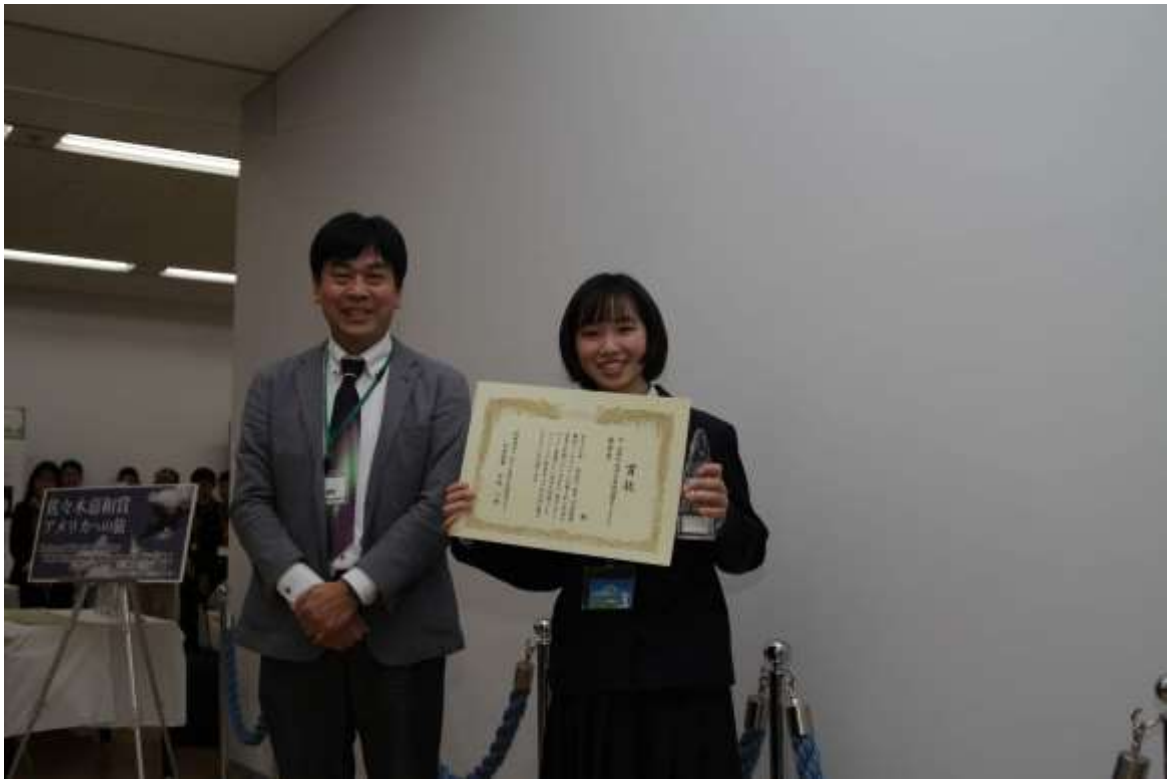

自律型水位観測アレイ
「長崎オリオンネット」

長崎県立宇久高等学校
１年　狭　間　富　稀

１．はじめに

宇久島は、九州北西部、長崎県西方海上の五島列島最北端にあります（**図１**）。真っ白な砂浜と真っ青な海が印象的な、一周 38km の小さな島です。人口は 1,974 人（2019 年５月１日現在）、その 63%が高齢者（60 歳以上）で占められており、年々高齢化が進んでいます。

近年、日本の各地で地震や津波、風水害などの自然災害が起こっています。宇久島でも直近数十年の地震・津波記録はありませんが、東北地方の例を見ても、地震が発生した場合は津波による被害が予想されます。

宇久島は、最寄りの都市である佐世保市本土まで約 50km あり、高速船でも２時間２５分かかるので、地震などですぐに逃げなくてはいけない場合、大勢で避難することは大変むずかしいです。また、島内には標高 50m の高台にヘリポートが一つあり、地震の際は、そこにそれぞれ避難するように申し合わせています。しかし、高齢者が素早く避難することは困難な状況です。

そこで、「いち早く津波を観測し、自分、家族、そして島民の命を守るため、水位観測機をつくろう」と決心しました。

また、宇久島には飛行場が無いため、島と本土を結ぶ交通手段は船しかありません。その船も海が荒れると欠航してしまいますので、私達は日頃から気象・海象情報へ強い関心を持って生活しています。**図２**は普段の宇久平港の様子です。

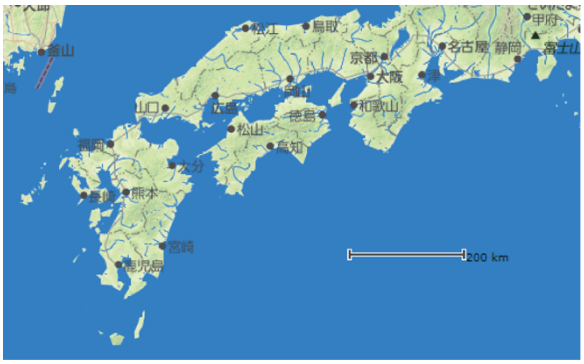

図１．宇久島の位置

図２．普段の宇久平港

しかし、海があれると、**図３**のようになります。私たちが住む宇久島および隣の小値賀島の周辺は大変荒れやすく、フェリーなどが抜港(ばっこう)することも頻繁にあります。抜港とは、船が接岸を諦めて次の港へ行ってしまうことであり、この報を聴くと島民は大変失望します。

宇久平港から佐世保港まで、海は広がっていますが、海の様子は一様ではなく、海の荒れ方に大きな差があります。なかでも宇久・小値賀の近海が特に荒れます。なぜ宇久・小値賀の近海だけが荒れやすいのか、小さなころからの疑問でした。

このことを研究するために、まずは、「どれくらい海が荒れやすいかを定量的に測定し、他の地域との比較をしたい」と考えました。

さらに長崎市では、春・秋にあびき現象がよく観測されます。あびき現象は、南方副振動が原因とする報告が先行研究で成されていますが、角力灘（すもうなだ）を取り囲むように観測点を配し水位変化を秒の解像度で同期して調べることで、「あびき現象を観測したい」という目的もあります。

これら３つの目的のため、観測機を自作し、長崎県本土と五島列島の沿岸に配置する計画をたてました（**図４**）。赤丸の位置が観測点です。観測予定の場所を結ぶと、たまたまオリオン座のような形になりましたので、本研究観測アレイを「長崎オリオンネット」と命名しました。宇久高はベテルギウスの位置にあります。

２．実験方法

本観測機は、arduino を基礎とし、センサに超音波距離センサ、温湿度気圧センサ、I²C 変換チップを介して GPS チップを配し、電源系にソーラーパネル、チャージコントローラ、鉛蓄電池を、通信系に IM920 チップおよびアンテナを使用しています（**図５**）。

図３．抜港時の宇久平港

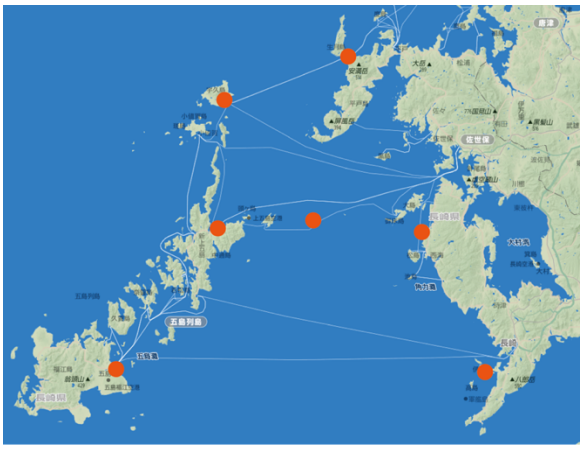

図４．長崎オリオンネット
赤丸は観測点です。宇久高はベテルギウスの位置にあります。

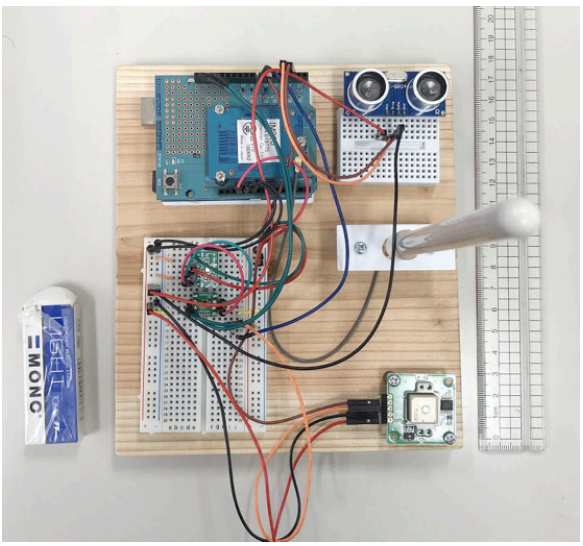

図５．観測機の技術モデル

得られるデータは、温度、気圧、水位（固定点のセンサーから海面までの距離）、GPS チップから、時刻、緯度、経度、ジオイド高です。水位（距離）を超音波で測定しているため、温度は音速補正に使用しています。

得られたデータは本体の microSD カードに csv 形式記録されるとともに、IM920 無線チップ（通し 7km の通信が可能）を介して送信されます。この無線チップで宇久平港から宇久高校まで毎秒１回観測データを送信し、理科室の PC で受信、蓄えたデータを、毎分１回 web を介してサーバにアップロードします。

長崎オリオンネットを構成する観測機は、食品タッパの中に arduino など本体を入れ、スチール骨材の先端に超音波測距チップをおき、水位変化を測定します（**図６**）。海岸に測定部が海上につきだすように設置し、24 時間観測します。その際、観測機を釣り人に海に捨てられないよう、測定中の紙を置いておきます。

マイコン arduino は、Ｃ＋＋に似た言語で開発します。**図７**は arduino の総合開発環境で、この画面でプログラムを組み、センサの出力をリスニングしたりして試行錯誤を行います。

図８の distance とあるところが、距離測定部です。超音波測距センサでは、距離を超音波で測定します。音速は温度の関数ですので、観測の際に温度もその場で測定し音速の温度補正を行いました。このことで、音速一定と仮定して測定していたときより、観測精度が２％ほど向上しました。

実際に宇久平港の岸壁に設置したところです（次ページ**図９**）。重しのコンクリートブロックは、高校の体育大会で使用したテント押さえの”おもし”です。単三電池４本をスマートフォンチャージャにいれて動かしていますので、電池交換が必要です。

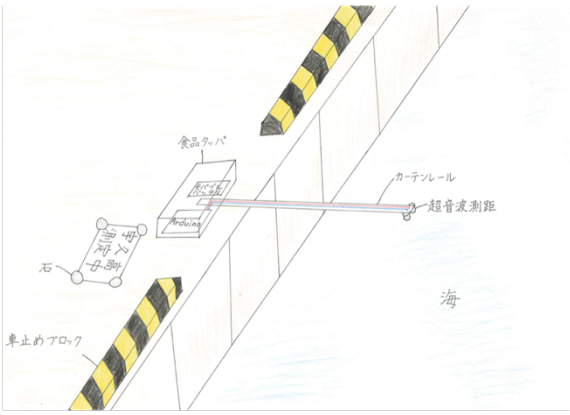

図６．観測機の設置方法

```
#include <SoftwareSerial.h>
#include <SD.h>

#define echoPin 2 // Echo Pin
#define trigPin 3 // Trigger Pin

const int chipset = 4; //イーサネットシールドは4

float a_in;           //analog input
float temp_c = 0;     //calcurated data temperature in C
String temp_c_str=""; //calcurated data temperature in C string
double Duration = 0; //受信した間隔
double Distance = 0; //距離
String Distance_str=""; //距離 string
double Sonic = 0; //音速
String gpsTime="";

//GPS rxPin = 6  txPin = 7
SoftwareSerial mySerial(6, 7);


void setup() {
  mySerial.begin(9600);
  Serial.begin(9600);
  pinMode( echoPin, INPUT );
  pinMode( trigPin, OUTPUT );
  Serial.print("Initializing SD card...");
  if (!SD.begin(4)) {
    Serial.println("initialization failed!");
    while (1);
  }
  Serial.println("initialization done.");
  PrintToFile("start!");
}
```

図７．arduino のプログラム

```
a_in = analogRead(A1);
temp_c = ((5 * a_in)/1024)*100;
temp_c_str = (String)temp_c;
        PrintToFile(temp_c_str);


//distance
  digitalWrite(trigPin, LOW);
  delayMicroseconds(2);
  digitalWrite( trigPin, HIGH ); //超音波を出力
  delayMicroseconds( 10 ); //
  digitalWrite( trigPin, LOW );
  Duration = pulseIn( echoPin, HIGH ); //センサからの入力
  if (Duration > 0) {
    Sonic = 331.5 + temp_c * 0.6;
    Duration = Duration/2; //往復距離を半分にする
    Distance = Duration*Sonic*100/1000000; // 音速を340m/sに設定
    Distance_str = (String)Distance; //  型を変換
  }

        PrintToFile(Distance_str);
        PrintToFile("");

delay(100);

//delay(5000);
  while(millis() - tick<9000){
  }
    }
  }
}



//subroutine for writing data in SD card
void PrintToFile(String dataIn){
  File dataFile = SD.open("DATA.TXT", FILE_WRITE);
```

図８．距離測定部

電池は６時間くらいで切れてしまいますので、観測期間中ずっと電池を気にしながら生活をしなければなりません。

夜から早朝にかけての電池交換は危険なため、顧問の先生がされました。夜はフナムシが観測機のケースにびっしりと張り付いており、ゴキジェットで追い払いながらの観測だったとのことです。昼は、幸いフナムシはいませんでした。

食品タッパの中に、アルディーノやバッテリがあります。防水仕様です（図 10）。発熱のためほんわかあたたかく、そのためか気温の下がった夜間、食品タッパ部分はフナムシに大人気です。

図９．観測機を設置した様子

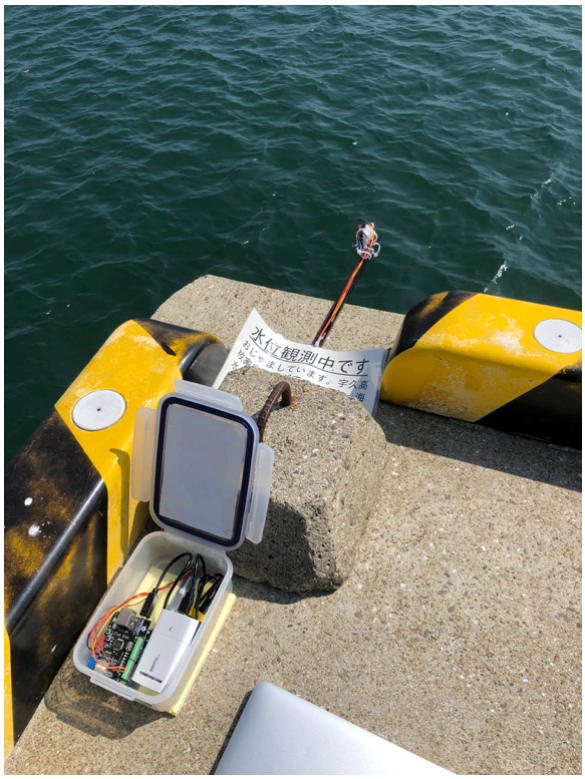

図 10．観測機を設置した様子２

３．観測結果と考察

予備実験として、10 月 9 日、6 時間ほど宇久平港で水位を測定しました（図 11）。

横軸は時間、縦軸は観測機から海面までの距離です。センサの位置は固定ですので、時間とともに距離が長くなっているのでこの図は引き潮を示します。測定間隔は 1 秒、1 日 24 時間測定で、観測データが 86,400 点得られます。
地球でもっとも影響の大きい月によるＭ２分潮のほかに、周期 15 分程度の海面変動も捉えられました。

同じ場所で、継続観測を行いました（次のページ図 12）。欠測の箇所もありますが、全体として海面変動を捉えることができました。上が干潮時の水位、下が満潮時の水位です。12 時間周期の単純な変動ではなく、より長期の変動も見えました。

12 日にデータがばらついているのは、台風 19 号の影響で、海面が荒れ、超音波の反射波が正しく返らないためと考えられます。台風通過後に同観測機で測定すると、正常な値を得ることができました。

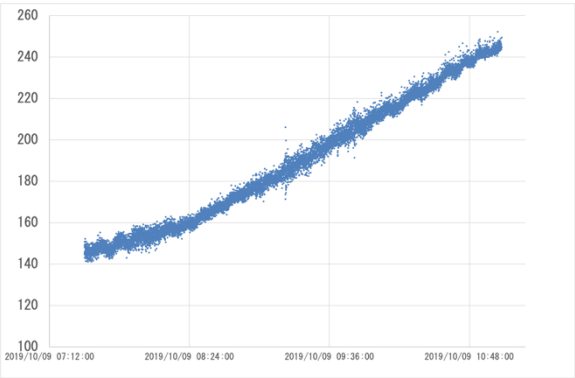

図 11．予備実験結果
縦軸は海面までの距離[cm]
横軸は時間[s]です。

宇久高校理科室において、気温湿度気圧のデータを測定しました（**図 13**）。赤色が気温、水色が湿度、緑が気圧です。台風 19 号通過のあと、気圧が上昇しているのがわかります。

予備実験の結果を受けて継続観測を行いました。10 月 12 日～14 日に、泊まりがけで観測旅行を行う予定でしたが、台風 19 号の影響で高速船もフェリーも欠航してしまったため、県本土と宇久島の同時観測ができなくなってしまいました。そこで、代わりに、宇久島の平地区（宇久島を時計に見立てて３時の位置）と神浦地区（６時の位置）で 24 時間の同時観測を行い、データ比較の技術検証を行いました（**図 14**）。横軸が時間、縦軸が観測機から海面までの距離です。青色が宇久平港、赤色が神浦港のデータです。宇久平港のデータが欠けているのは、風の影響による欠測です。

神浦港の干満のタイミングが宇久平港のそれよりも遅れていることが検出できました。

図 15 は先ほどの比較実験に、気温データを加えたものです。また、**図 16** は、比較実験に気圧データを加えたものです。

一般に気圧が 1hPa（ヘクトパスカル）下がると、海面は 1cm 吸い上げられるといわれていますが、今回のデータでは、気圧の低い 14 日夜の満潮よりも気圧の高い 15 日朝の満潮の方が潮位が高く、潮位変化が月の引力と気圧だけの影響ではないことを読み取ることができます。

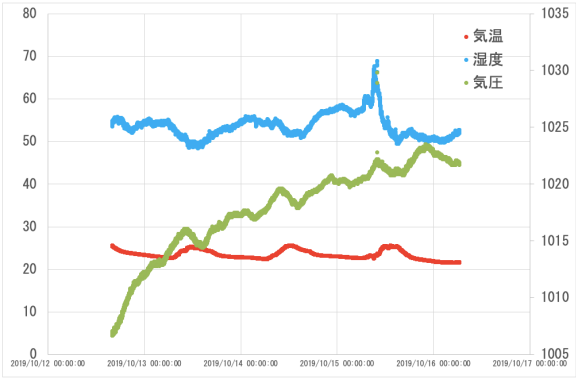

図 13.　気温湿度気圧の測定結果

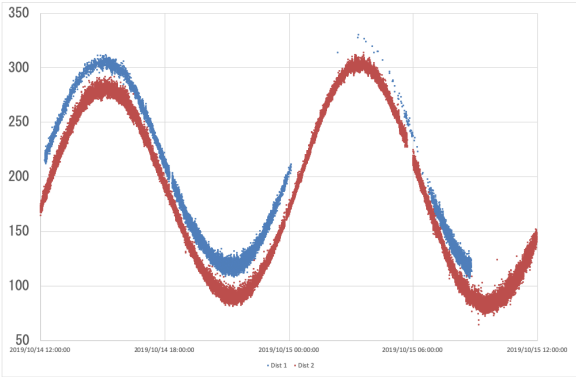

図 14.　宇久島内 2 点観測結果の比較

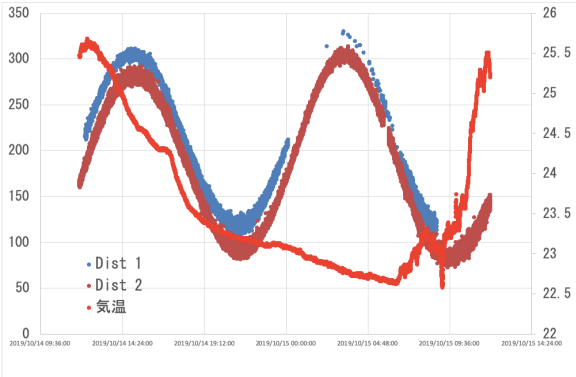

図 15.　観測結果の比較（気温変化）

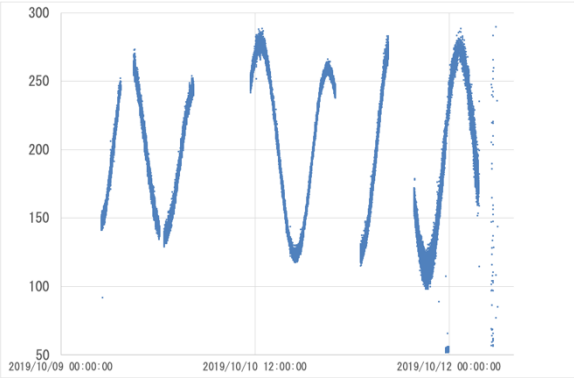

図 12.　継続観測の結果

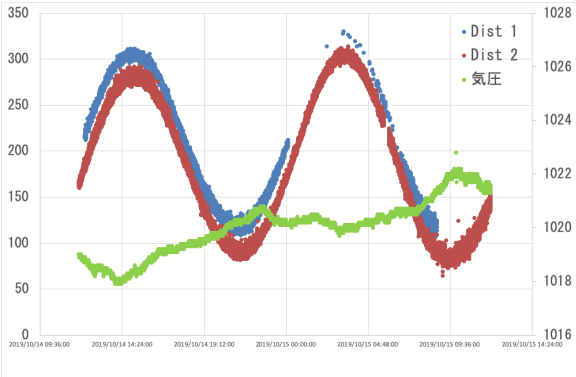

図 16.　観測結果の比較（気圧変化）

４．まとめと今後の予定

今回の研究で、①時間分解能を高めた海面変動量を定量的に測定し、他の地域と比較するシステムを構築し、技術検証ができました。②宇久高理科室のサーバを基点に、各地の観測機からリアルタイムの水位データを収集し、津波を検出する津波観測網のシステム構築を行い、技術検証ができました。また、③Ｍ２分潮、Ｓ２分潮とも違う周期の短い海面変動を捉えることができました。

今年度の取組みで、宇久高校のサーバにデータを蓄積するシステムができました。今現在もデータを収集しています。それぞれの観測点から近くの高校まで、IM920 による無線通信でデータを送信、各高校から宇久高校サーバまでは長崎県の教育ネットを利用してデータを集めます。崎戸町江島（さきとちょうえのしま）には教育ネットがありませんので、ソフトバンクの IoT 向けナローバンドサービスを利用します。月 60 円の使用料で低速通信できます。

この秋、長崎県内の高校に向けて長崎オリオンネットを説明し、コンソーシアムを形成する予定です。

５．謝辞

本研究は，一般財団法人　気象文化創造センターからの助成を受けて行いました．ここに記して感謝いたします．