

目 次

巻頭言

- ・キーワードは共有と協力 次期支部長 張 樹槐

研究報告

- ・除草（芝刈）ロボットの農業利用試験 金井源太・好野奈美子 . . 1
- ・Rice Tiller Detection using Deep Learning and Field Robot
 Dhirendranath SINGH・Shigeru ICHIURA・Thanh Tung NGUYEN・Mitsuhiko KATAHIRA . . 5
- ・エチオピアでの米のポストハーベストと農作業について 片平光彦 . . 9
- ・アイマークレコーダーを利用した家畜状態把握時の家畜管理者の注視特性
 今野真輔・比留間秀哉・堀口健一・片平光彦 . . 13
- ・データセットに含むエダマメ品種の違いによる物体検出 AI のエダマメ外観品質分類精度の変化・ 森 智洋・片平光彦 . . 17
- ・マメ科混播草地における草種識別法の検討（第二報） 大出亜矢子・田中勝千 . . 21

トピックス

- [令和 2 年度東北支部大会（WEB）報告] 25

支部会記事

- 庶務報告及び会計報告 27
- 令和 2 年度研究発表会発表課題 35
- 農業食料工学会東北支部役員及び役員体制 37
- 農業食料工学会東北支部規約・表彰規程と内規・役員選挙規程・投稿規程 39

- 東北地域農業食料工学関係の研究担当者名簿 46

- 団体賛助会員名簿・個人会員名簿 52

キーワードは共有と協力

次期支部長 張 樹槐

1. はじめに

新型コロナウイルスが最初に報告されてからすでに1年以上を経ちますが、世界的な感染状況が収まるところか、引き続き拡大していると言わざるを得ない現状にあるでしょう。この1年間、テレワークやリモート講義、3密状況になりにくい圃場などでの実験は何とか実施できていると聞きますが、複数で行う室内実験などの一部が制限されて、卒業研究や修士研究などのデータ取得に支障をきたしていることを直に経験しています。会員の皆さんにとっても、仕事や生活に何かと不便を強いられていることかと思えます。このような不安の状況下に、希望がもたれる明るいニュースとして、昨年末より新型コロナウイルス用のワクチンが各国で緊急承認されて、欧米諸国を中心に一部大規模の接種も始まっていて、特に問題となる副作用の報告もなく、順調に進んでいると報道されています。専門家でない私にできることは、一日も早くいつもの日常が戻るよう願うのみです。

前置きが長くなりましたが、この度2021、2022年度の支部長に拝命した張 樹槐(チャン シュファイ)です。前支部長の田中勝千先生はじめ、諸先輩方のような力量がなく、どうしようかと迷いながら拒否できないと言われたこともあり、お引き受けしました。会員の皆さんのご協力の下、微力ながら東北支部の発展に尽力してまいりたいと考えておりますので、どうぞよろしくお願いいたします。

2. 東北支部を取り巻く状況

諸先輩支部長の巻頭言を改めて読み返してみると、日本農業や農業機械の変遷や現状などをそれぞれの視点で総括・分析しております。この話題は私にとって、あまりにも広すぎて難しいので、武田純一先生の巻頭言(支部長No.63)にある東北支部の現状という内容にならって、皆さんとともにそれを再確認してみたいと思います。

支部会の発表件数ですが、2020年度を除いて、その後も大きな変化がなくほぼ20~30件で推移しています。特筆すべきなのは、新型コロナウイルスの影響で、2020年度の支部大会が中止されたものの、田中勝千支部長、大出亜矢子事務局長のご努力と大学関係会員のご協力で、学生を中心に計12件の最新成果発表会をZOOMによるWEB形式で実現できたことです。

支部報の研究論文数は、編集幹事片平光彦先生のご努力も実らず、以前の平均12件と比較して、No.64(2017)の8件、No.65(2018)の4件、No.66(2019)の9件と低迷気味です。コロナの影響でNo.67(2020)の締切は2021年1月末に設定していますが、楽観できる状況にないと感じています。

支部会員数は、2016年の89名から大きな変動がなく、会員の皆さんのそれぞれのご尽力に頼るしかありませんが、これと言った拡大できる妙案も思いつきません。個人的に気にしているのは、東北支部に所属している農業食料工学会の会員が減少傾向にあることです。東北農業研究センターを別にして、各県の農業試験場に籍がある方で、全国学会の会員が果たして何名いるのでしょうか?個人情報保護法の関係で、近年学会誌に会員名簿がなく、すぐに具体的な数字を挙げられないが、おそらく1桁しかないでしょう。また、機械を専門にしている大学教員も、各大学の事情もあるでしょうが、関係者の退職後の補充もなく、減少の一途です。これが、学部学生や大学院生の減少にも拍車をかけており、東北支部の将来にとって大変憂慮される事態になっていると考えます。

暗い数値ばかり羅列しましたが、明るいニュースもあります。その中で何と言っても、2019年4月福島大学に農学系学部が新設され、機械を専門にしている教員が赴任されたことでしょう。早速、大学関係者含めのご協力の下、2019年の支部会が福島大学で開催できました。これから年次進行で機械を専門にする学部学生や大学院生も増えてくるだろうと大いに期待しております。

3. これからの東北支部

上述した東北支部の現状から考えると、機械を専門にしている研究者数は、福島大学に新しい研究者が赴任された以外、特に改善される状況がなく、今後の大学での教育・研究や東北支部の管理・運営などのためにも、私はこの文章のタイトルにある“共有と協力”をキーワードに選びました。

このキーワードを思いついたきっかけは、2011年に開催された第70回農業機械学会弘前大会でした。当時、弘前大学の

機械教員は高橋昭夫先生、福地博先生と私の3人でした。高橋先生が2009、2010年度の東北支部長を務められた関係で、2011年度の全国大会を引き受けたと聞いております。関係教員が3人だけでは、滞りなく全国大会の開催が難しいと考え、当時の夏賀元康東北支部長や常任幹事などの皆さんに全面協力を依頼し、オール東北の体制で全国大会を無事に終えることができました。その流れで、後に岩手大学で開催された農業環境工学関連5学会2015年合同大会でも、東北支部全体として関わったと記憶しております。

この精神を今後も引き継ぎ、大いに活かしていきたいと考えております。このような“共有と協力”体制の前例として、私が参加したことがないけど、定期的開催されている東北農業試験研究推進会議・作業技術研究会が実質的に行われているのではないかと推察しています。それと比較して、大学などの教育機関には、このような体制がないため、今後大学などの研究者数がさらに減少していく中、お互いの情報を共有して、協力していくことが何よりも大事かと思えます。

この仕組みを具現化していくために、今後常任幹事や幹事、会員の皆さんの意見を聞きながら詳細を決めることになりませんが、以下のことをぜひ実現したいと考えております。

1) 各機関の研究テーマの情報共有

支部会HPでは、最新刊を除く以前の支部報が全文PDF化され公開しています。読んでみると、初期とある時期の支部報には、最新の研究成果としての研究論文以外に、大学の諸先生方や各県の研究機関などが当該年度の研究テーマを紹介しています。

例えば、創刊号No.1(1957)には、以下の記述があります。

山形大学土屋先生

- ・水田土壌の耕耘性に関する研究（継続）
- ・車輪ラブの研究（注：時代を感じるだけでなく、親近感も！）
- ・エンシレージカッター（注：Ensilage Cutter, Silo Filler, 粗飼料の細断・サイロ詰用機械）
- ・自脱の試作（注：自脱コンバインのこと？）
- ・粃・玄米の選別に関する研究（注：現在にも通じるテーマ！）

山本製作所技術部

- ・A エンシレージカッターの送給動力を測定する。
- ・B 切断材料の種類が切断抵抗への影響を調べる。（注：文意より張がまとめた。）
- ・C ベルト伝導がカッターの送給機構に利用可能かを調査する。（注：文意より張がまとめた。）

これらの内容から、当時の研究テーマもかなり多様性が富んでいるだけでなく、大学と民間企業の共同研究を盛んに実施していることが伺えます。

これらの良い伝統をぜひ復活してみたいと考え、毎年の支部報には各大学や研究機関の直近の研究テーマなどを掲載して、それらの情報共有を通じて、実験手法や測定機器の相互補完、さらに将来的に共同研究へ発展できればと期待しています。研究総括や編集担当の常任幹事、大学・研究機関の担当者の皆さんに大変お手数をおかけすることになりますが、これから効率的な仕組みを皆さんと考えていきたいと思っています。

2) 会計の健全化

常任幹事会や幹事会などで毎回議論していますが、改善できる方策が見いだせないままとなっています。前会計担当幹事の折笠先生が提案している投稿料や別刷り料などの改正も視野に積極的に議論していきたいと考えています。

4. おわりに

任期の2年間に取り上げたい課題を2つしか挙げておりませんが、会員拡大、情報発信、若手の会等々について、諸先輩支部長の考えを共有しつつ踏襲していきます。会員の皆さんからの忌憚のないご意見を頂きながら、東北支部の諸活動を推進していきたいと思っていますので、どうぞよろしくお願い申し上げます。

また、研究者の間だけでなく、世間でもスマート農業というキーワードが広く認知されている中で、機械を専門にしている我々にとって願ってもないこのチャンスを逃さないように、“共有と協力”をキーワードに共に頑張りましょう。

除草（芝刈）ロボットの農業利用試験報告

金井源太*・好野奈美子*

Application of Automatic Lawn Mower to Agriculture

Genta Kanai, Namiko Yoshino

[キーワード] 芝刈ロボット, 除草, 雑草管理, 法面, 果樹園

1. はじめに

(1) 背景

農業人口の減少に伴い、あらゆる農作業で省力化は喫緊の課題である。その中でも雑草管理（除草）作業は直接的な農業生産活動ではなく、自動化、省力化により農業生産活動に注力することで、農業者の労働生産性向上につながることから必要性が高い。一方で、車体下の回転刃で草を切断する機構を持つ市販の芝刈ロボット（Husqvarna 社 Automower, Honda 社 Miimo）や除草ロボット（和同産業 Kronos）などは、作業対象地を規定する電線（エリアワイヤー）範囲内ではあるが、自動作業が可能で雑草管理を省力化できると考えられる。

筆者らは芝刈ロボットの各種果樹園における運用、耕作中断圃場での作業頻度に関する報告¹⁾を行い、農業利用での基本的な可能性を示した。ここでは営農現場を想定した一定期間の利用試験を行い、現地で利用する際や除草ロボット開発の際に参考となる情報の提供を目的とした。具体的には、雑草管理が必要な圃場周囲を想定した試験、斜面での運用試験、リンゴ果樹園での下草管理試験を行った。

2. 圃場周囲を想定した試験

(1) 試験方法

圃場の周囲での雑草管理を想定し、表 1 に示す日程で、図 1 に示す約 590 m² エリアの雑草管理試験を行った。試験圃場（福島県飯舘村）では、電源として太陽光給電装置（太陽光パネル:244W x 2 枚, 蓄電池容量:2.2kWh, オルテナジー社製）を設置、利用した。運用に際して、定期的な見回りは行わず、Web カメラによる監視により異常が発生した際に復旧に向かうこととした。

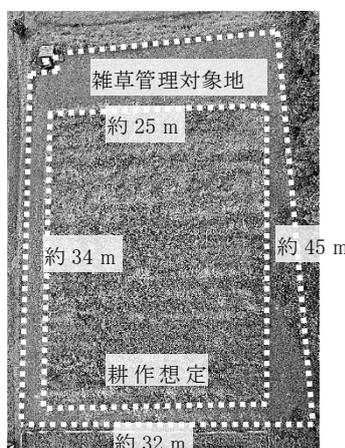
表1 現地圃場(福島県飯舘村)での運用試験概要

試験日程	供試機体	推奨面積 [a]
2020/5/21~8/6	Miimo HRM520	30
8/6~8/26	Kronos MR300	30
8/26~9/14	Automower 450X	50
9/14~9/30	Miimo 海外仕様機	40

(2) 結果および考察

いずれの機体も対象面積に対して推奨面積は十分であり、順調に作業している期間は、問題なく雑草を管理でき

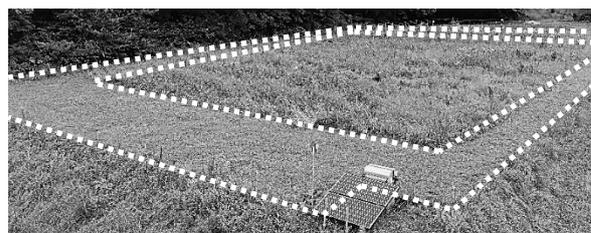
た(図1)。推奨面積が30aの機体で推奨作業時間は約4.7 h/day となるが、導入試験の結果、3.5 h/day 以上であれば、ほぼ設定草高に維持することができた。運用試験に当たって、エラー停止から復旧作業までの日数が掛かってしまい、草高が高くなる時期があった。



(a)試験地概要



(b)獣害により外れたワイヤーカバー



(c)太陽光給電装置と試験地

写真1 試験概要

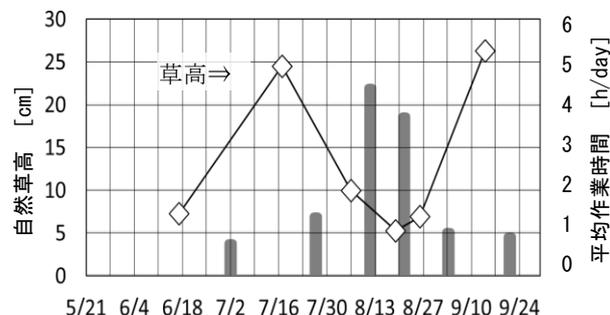


図1 雑草*の草高推移と草高測定日間の平均作業時間
* 主な草種:カモガヤ, シロツメクサ, ヒメジョオン, イヌビエ, エゾノギシギシ, コヌカグサ

* 農業・食品産業技術総合研究機構 東北農業研究センター福島研究拠点 福島県福島市

設置期間中、主なエラー停止要因は、設置時にエラー要因となる地面の凹凸を見つけきれずに対応できなかった部分でのスタック (13 回)、イノシシなどの害獣によるエリアワイヤーの切断による停止 (8 回) であった。その他、夜間運転を行う設定とした際や梅雨時期など雨天が続いた際には太陽光給電装置の過放電、充電不足による停止も発生した (2 回)。省力的な管理が必要となる労働力不足が深刻な地域では、獣害も発生しやすいと考えられ、本装置の導入に際して留意する必要がある。本試験ではエリアワイヤーを地表に専用ペグで固定したが、地中敷設を行うことで、獣害による切断リスクは軽減されると考えられる。

3. 斜面での運用試験

(1) 試験方法

農研機構敷地内 (福島県福島市) の最大値 25° の斜面 (約 140 m^2) を含む区画 (2019 年 5~6 月: 約 390 m^2 , 7~9 月に拡大: 約 510 m^2) にて Automower450X を用いた試験を行った。作業時間はおおむね面積あたり推奨時間とし、1 日 2~4 回程度見回りを行った。取扱説明書によると、仕様上、エリアワイヤーの位置での最大傾斜は 8.5° 、作業エリア内の最大傾斜は 24.2° とのことである。タイムラプスカメラで 5 秒ごとに撮影し、人手で復旧した場合を外的要因による停止とした。また、凹凸など対処可能な要因については、穴を埋める、ならすなどの対応を行った。

(2) 結果および考察

表 2 に月ごとの停止回数を示した。拡大したエリアでは雑草が繁茂していたことから、拡大直後の 7 月には斜面以外の部分での雑草の株への乗上げによるエラー停止が多かったものの、通年では斜面でのエラー停止が多かった。作業日 1 日あたりの値は斜面の場合を除くと 1 回以下となった。植生が薄く、石や枯草があり仕様上の最大斜度に近い場合、滑落も発生した。滑落時の加速度によりエラー停止となる事例も観察された。また、同じく仕様上の最大斜度に近い位置でススキなど雑草株への乗上げや掘返しによる停止が発生する事例もあった。特に掘返しについては、導入当初は走行可能な斜度であっても、その部分の作業を繰り返すにつれて斜面の特定部分が削れ、導入期間が長くなるにつれて掘返しの深さが深くなり、走行不能な凹凸になってしまう様子が観察された。掘返しが観察された場合には走行不能となる前に対策が必要である。

圃場周辺の法面や畦畔など、斜面における除草作業は慣行作業では作業者の負荷が大きく、自動化メリットが大きいが、仕様の範囲を超えないよう留意が必要である。

表 2 斜面を含む対象地でのスタック

試験期間	スタック回数 (斜面, その他) [回]	月作業日数 [日]	平均スタック回数 (斜面を除いた回数) [回/日]
2019/6 月	17 (17, 0)	12	1.4 (0)
7 月	20 (8, 12)	12	1.7 (1)
8 月	21 (16, 5)	13	1.6 (0.4)
9 月	15 (11, 4)	13	1.2 (0.3)

4. 果樹 (リンゴ) 下草管理

(1) 2019 年試験

農研機構内リンゴ果樹園 (384 m^2 : $24 \text{ m} \times 16 \text{ m}$, 岩手県盛岡市) にて, Miimo (HRM520) を約 2 ヶ月 (2019/8/9~10/9) 運用した。推奨運用時間は 3.1 h/day (充電除く: 1.7 h/day) であるが、ここでは約 2 倍の平日 6 h 運転 (充電除く平均作業時間: 2.0 h/day) の設定とした。

常駐させて雑草を短く管理する装置の特徴から、本来は雑草が繁茂する前の時期からの導入が望ましいが、試験の都合でシーズン途中からの導入となった。そのため、既に繁茂していた周囲の雑草は乗用管理機で除草し、その後に設置した。樹間については導入前の除草が遅れ、導入当初は雑草が 75 cm 程度まで繁茂しており、エラー停止が頻発したが、導入後の 8 月中に芝刈ロボットで作業できる状態まで刈払機にて除草を行った。運用に関しては、1~2 回/日の頻度で見回りをを行い、エラー停止していた場合には再稼働させ、停止要因の除去を行った。タイムラプスカメラ (5 秒毎) による観測で作業時間およびエラー発生を判定した。なお、撮影範囲からの死角のため、確認できる範囲での計測となった。写真 2 に示すとおり、平均作業時間としては、推奨運用時間に達しなかったが、1 日 1~2 回程度の適切な装置管理により雑草管理を行うことができた (表 3)。特に 9 月以降の時期には、既報¹⁾でも発生した落果に乗上げることによる停止が発生したため、手作業で除去する管理を行い、エラー回避に努めた。

写真 2 の左端列の株元には、有用な天敵であるカブリダニの生息に有利なアップルミント²⁾が植えてあるが、本装置導入によっても、果樹の幹により進行を妨げられるため、刈り取ってしまうことはなく、株元については試験終了時まで残存していた。



写真 2 タイムラプスカメラによる運用試験の様子 (2019)

* 8/9 と 8/20 の間に刈払機除草を行った。左端列の株元の植生はアップルミントである。

表 3 リンゴ下草管理試験 (2019)

期間	平均作業時間 [h/day]	設定時間に対する割合 [%]	管理状況 (平均草高, 主な草種)
8 月	1.6	82.5	草高: 27.1cm, 草種: メヒシバ, シロツメクサなど (8/9 測定)
9 月	1.7	84.3	-
10 月	1.4	72.3	草高: 7.3cm, 草種: シロツメクサ, ヒメムカシヨモギ (10/31 測定)

(2) 2020年試験

農研機構内リンゴ果樹園 (460 m²: 23m x20 m, 岩手県盛岡市) にて, Miimo(海外仕様機)を約 5 ヶ月 (2020/6/9~10/26) 運用した。推奨運用時間は 2.8 h/day (充電除く: 1.8 h/day) であるが, ここでは平日のみ 5 h 運転(充電除く平均作業時間: 3.3 h/day)の設定とした。電源には市販の太陽給電装置 (SP-120 和同産業製, 太陽光パネル:110 W, 蓄電池:55B24R x2 個) を改造したものを用いた。設置場所付近に防風林がある事も 9 月以降は十分な発電が行えず, 作業時間への影響があった。平均作業時間としては, 推奨運用時間に達しなかったが, 1 日 1~2 回程度の適切な装置管理により雑草管理を行うことができた。導入エリア内の期間内平均草高は 11.3 cm, 導入エリア外(隣接するリンゴ果樹園の慣行区)は, 26.5 cm であった。導入当初, ギシギシ繁茂箇所でのエラー発生があったが, 除草剤のスポット処理により解消された。また, 9 月以降の落果については 2019 年度と同様に手作業により除去し, エラー回避に努めた。



写真 3 タイムラプスカメラによる運用試験の様子(2020)
* 株元の雑草は残っているが導入エリアでは雑草管理できている。

表4 リンゴ下草管理試験(2020)

期間	平均作業時間 [h/day]	設定時間に対する割合 [%]	管理状況(平均草高, 主な草種)
6 月	2.2	65.3	草高:20.5 cm, 草種:シロツメクサ, エゾノギシギシなど(6/9 測定)
7 月	1.9	55.7	-
8 月	1.8	53.0	草高:7.3 cm, 草種:シロツメクサなど(8/4 測定)
9 月	1.7	52.0	-
10 月	1.6	47.7	草高:6.2 cm, 草種:スズメノカタビラ, イヌタデ, シロツメクサなど(10/29 測定)

その他, 枝下など乗用管理機では作業が困難で, 慣行では除草剤処理や刈払い機による作業を行っていた部分についても, 本装置導入による除草作業が可能となる場合が

あった。安全を確保する装置の仕様から, 機体周囲から刈刃までは数センチ以上の間隔が空いており, 果樹の株元は刈残したが, エリア全体では十分に管理できていた。

4. 今後の課題

(1) 接地圧と踏圧

供試機体の接地圧を概算すると 0.2~0.3 kg/cm² となる(表 5)。一方, 車輪トラクタは 0.8~1.5 kg/cm², 自動履帯コンバインは 0.2~0.5 kg/cm², 人の足は 0.4~0.5 kg/cm² である³⁾。これらの値と比較して, 芝刈(除草)ロボットの接地圧は, 比較的, 低い値である。しかしながら, 芝刈ロボットは無人作業で繰り返し走行するため, 作業対象地では踏圧による土壌の圧密についても留意が必要と考えられる。地耐力の無い圃場での作業や踏圧による影響を考慮すると, これらのロボットについて車輪の幅を増したり, クローラーとするなど接地圧を減ずることも検討する必要がある。

表 5 接地圧の概算

	接地圧概算 [kg/cm ²]	機体重量 (カタログ値) [kg]	車輪幅 (機体実測値) [cm]
Miimo HRM520	0.21	11.9	前輪:4.3 後輪:3.1
Kronos MR300	0.33	16	前輪(1輪):4 後輪:4
Automower 450X	0.23	13.9	前輪:4.4 後輪:3.2
Miimo 海外仕様機	0.23	13.8	前輪:4.3 後輪:3.3

* 接地面積: 進行方向の接地長さは車輪の沈む深さによるが, ここでは車幅と同等と仮定した。

(2) 果樹園の環境に与える影響について



(a)刈高さ 2cm での作業(2019)



(b)刈高さ 4 cm での作業(2020)

写真 4 落葉への影響(左:装置導入エリア, 右:エリア外)

リンゴ園内のクローバでミチノクカブリダニについて,

草丈 80 mmでの管理が 10 mmでの管理よりも高密度に維持できるとの知見がある^{4) 5)}。本装置では伸びた雑草を一度に刈り倒す慣行作業と異なり、常に少しずつ刈ることで草丈を一定に維持するため、害虫や天敵の環境攪乱が少ないと想定されるが影響は不明である。今後、害虫やその天敵の生育環境や挙動への影響を検討し、果樹生産にとって望ましい適切な運用を行う必要がある。

ナシ黒星病軽減のため秋のうちに落葉の粉碎処理が有効との知見⁶⁾もあり、落葉処理は基本的な対策の一つとされている⁷⁾。落葉が春先まで地上に残っていると次年度の感染源となるため、粉碎・分解や埋没などで地表に残っていないことが望ましいとのことである。予備的な試験で装置(Miimo 海外仕様機)を晩秋まで運用した場合、写真4のように落葉が目立たなくなった。刈刃による切断と装置の車輪による踏みつけによる結果と考えられるが、ナシ黒星病予防の観点から本装置の適用がどの程度効果があるかは不明であるが、引続きデータ蓄積予定である。

謝辞

本報告には、農林水産省「食料生産地域再生のための先端技術展開事業」による知見が含まれます。また、果樹園での試験では、農研機構果茶部門 岸本英成上級研究員にご協力頂きました。ここに謝意を表します。

参考文献

- 1) 金井源太・好野奈美子, 2020, 市販芝刈ロボットの農業利用の可能性, 農業食料工学会誌, 82, 412-414.
- 2) 農研機構, 2011, 生物の多様性を維持する果樹・茶の管理技術, p. 3, https://www.naro.affrc.go.jp/publicity_report/publication/files/fruit_tayousei_kannri.pdf (2021-1-28 確認)
- 3) 農業機械学会, 1984, 新版農業機械ハンドブック, コロナ社, 358-359.
- 4) 農研機構, 2020, 新果樹のハダニ防除マニュアル, 12-13, https://www.naro.affrc.go.jp/publicity_report/publication/files/2020330nifts_hadani_tec_manual.pdf, (2021-1-28 確認)
- 5) 岸本英成・榊沼勝彦・降幡駿介・外山晶敏, 2020, 草刈りの高さがリンゴ園下草でのカブリダニの発生に及ぼす影響, 日本ダニ学会誌, 29(2), 47-58.
- 6) 舟橋志津子, 2019, ナシ黒星病の落葉処理による被害軽減効果, 植物防疫, 73(9), 27-32.
- 7) 梅本清作, 2013, おもしろ生態とかしい防ぎ方ナシ黒星病, 農文教, 2013.6.30. 31-36.

Rice Tiller Detection using Deep Learning and Field Robot

Dhirendranath SINGH¹, Shigeru ICHIURA¹, Thanh Tung NGUYEN², Mitsuhiko KATAHIRA²

Abstract

Growth monitoring is a critical aspect in agriculture production. The application of Artificial Intelligence (AI) and Remote sensing in agriculture is increasingly being researched as they have the potential to significantly reduce labour necessary for some of the more tedious tasks. In rice cultivation, the monitoring of tiller number at the vegetative growth stage remains one of the most tedious and time consuming task at the field level, as it is still being done manually. Thus, a less labour intensive approach is needed. In this study, we explore the use of remote sensing and deep learning for detecting tiller number of rice plants in field conditions, at the most active tillering stage. Images for training AI models were collected using a field robot, from an experimental plot at the Field Science Center, Faculty of Agriculture, Yamagata University, Japan during June 2020. The number of tiller per plant was manually counted for each plant in the captured images. To determine at which point accurate detections can be obtained, we explored tiller detection with six data sets of different class ranges; actual tiller number, grouped tillers into 2,3,4 5 tillers per class and a class range based on the distribution tillers per plant at the growth stage. Models were trained using YOLO V4 algorithm on the Darknet framework for 30,000 iterations after which they were evaluated for precision, recall and mAP. The trained models gave low precision (0.11), recall (0.12) and mAP (9.17) for detecting actual tiller number. However, promising results were obtained; precision (0.64), recall (0.76) and mAP (67.5) using class range based on distribution.

Keywords: crop sensing, deep learning, precision agriculture, rice tiller, YOLO

1. INTRODUCTION

Growth monitoring is a critical aspect in agriculture production. Traditional methods involve manual measurements which are often tedious, time consuming and only capable of measuring a sample which guides management decisions for the entire field. Remote sensing and Artificial intelligence is capable of collecting and analyzing large amounts of data thereby offering the opportunity to provide more complete and detailed data for guiding management decisions. In recent years, the use of AI and Remote sensing in agriculture is increasingly being researched as they have the potential to significantly reduce labour necessary for some of the more tedious tasks. In rice cultivation, tillering is considered to be one of the most important agronomic traits, as tiller number per plant plays an important role in determining effective panicle which is a key component of grain yield (Bian et al., 2015). Deep Learning was used by (Deng et al., 2020) to detect productive tillers in rice, but the method requires exposure of the cross-section of the culm by harvesting at maturity. Since the vegetative stage of rice growth provides the best opportunity for management practice to influence yield (Al-Khatib et al., 2018), an efficient method to detect tiller numbers during growth is needed. In this study we explore the use of YOLOv4 (Bochkovskiy et al., 2020) a fast and accurate deep learning algorithm to detect tiller number in rice during active tillering from images captured using a field robot. It is envisioned that this combination can provide detailed growth information for an entire field to allow better management of the rice crop.

2. MATERIALS AND METHODS

2.1 Field Description

Images for training AIs were collected from an experimental plot in which a crop nutrition trial was being conducted at the Field Science Center, Faculty of Agriculture, Yamagata University, Tsurouka City, (38°41'52.9"N 139°49'20.3"E). The field was cultivated with the Fukuhibiki (*Oryza sativa L.*) variety which is a high yielding Japonica type variety used primarily for forage (Fukushima, 2012). Ten nutrition treatments of different rates of phosphorous and potassium fertilizer were applied to the field in 3 replications providing a total of 30 test plots.

2.2 Field Robot Outline

The field robot used in this study was specially designed to traverse the flooded conditions concomitant with irrigated rice cultivation. Its dimensions are L 1400 mm x W 1200 mm x H 1450 mm with a wheel diameter of 650 mm. The wheel type is similar to those used on rice transplanting machines. It weighs approximately 180 kg and is powered by two 12volt batteries which rotates each of the 4 brushless electric motors (200W, 3000r/min Orientalmotor, Model BLVM620KM-GFS, Japan). It has sensors for Temperature and Humidity (SHT31 module), sunshine (Sanko PV Array Pryanometer PVSS-01), Airspeed (Powerday Airspeed sensor), and RTK GPS (Ublox ZED F9P) connected to Ardupilot's Pixhawk2 flight controller. A parabolic antenna mounted on the top gives a remote-control range of beyond 160 meters and an adjustable camera mount on the front of the robot holds two Sony action cameras used for image and video capture.

2.3 Image Acquisition

¹Department of Agricultural and Environmental Engineering, Biotic Environmental Science, The United Graduate School of Agriculture Sciences, Iwate University (UGAS)

²Department of Food, Life and Environment, Faculty of Agriculture, Yamagata University

Images were captured using a Sony FDR-X3000 action camera in HD (1920 x 1080 pixels). The camera was mounted on the robot at approximately 1 meter above the canopy and had a Field of View of 1340 mm by 820 mm. Image capture was executed using the cameras remote function. The locations to capture images were decided by placing 150 markers in the field (5 per test plot). The robot was then positioned so that the marker was in the center of the image frame, and the 4 edges were demarcated with poles. In each image, 16 plants (4 rows x 4 plants per row) were captured. In some cases, more than one image was captured per maker to ensure all plants are fully in the frame. The data presented in this report focuses on images captured during June, 2020 at 6 weeks after transplanting.

2.4 Ground Truth data collection

After image capture the tiller numbers, plant height and leaf color (Konica-mionolta, SPAD-502) of each captured plant in the image frame was measured manually

2.5 AI Development

(1) Object detection algorithm

In this work we use YOLO V4 (Bochkovskiy et al., 2020) on the Darknet framework for detecting tiller number of rice plants. YOLO V4 is the fourth version of the you only look once (YOLO) algorithm originally developed by Redmon, Divvala, Girshick, & Farhadi, (2016). Bochkovskiy et al., (2020) verified and selected a large number of features from the ‘Bag of freebies’ and ‘Bag of Specials’ to improve YOLO v4’s architecture making it faster and more accurate than all alternative detectors. ‘Bag of freebies’ refers to a group of methods that only changes the training strategy or only increase the training cost such as data augmentation, while ‘bag of specials’ refers to those plugin modules and post-processing methods that only increase the inference cost by a small amount but can significantly improve the accuracy of object detection

(2) Tiller Detection

In our previous experiments we annotated plants by visually judging the appearance of the plant and canopy size based on which estimated tiller range was assigned. The trained models gave encouraging results and was used to assess images from the entire field. In this work, we investigate methods to improve AI accuracy, by annotating plants with the manually counted tiller number per plant instead of visually estimating the number of tiller per plant.

Data Sets

The captured images were duplicated six times to create 6 data sets. For each data set 17 images were selected to create the test data. The remaining images (223 images) were used for training models. Each of the 6 training data set were annotated (Vott Version 1.7.2, Microsoft) with a different

class range, to determine at which point accurate detections can be obtained. Three approaches to class ranges were used:

- Actual tiller number: plants were annotated with the manually counted tiller numbers.
- Grouped: classes were derived by using class ranges of 2, 3, 4 and 5 tillers per class.
- Distribution: based on the 3,468 plants counted, three classes were determined based on the distribution of plants at each tiller number (Fig.1)

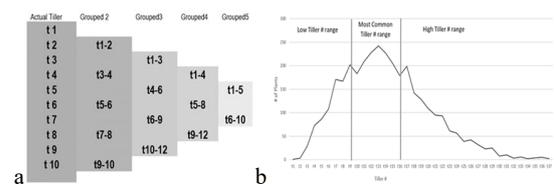


Figure 1 Illustration of training data set preparation for each data collection date: (a) Actual and Grouped tiller ranges, (b) Distribution of tiller ranges.

(3) Training

Training was executed for 30,000 iterations using the training environment shown in Table 1.

Table 1 Training environment used for Ai development

PC	Ubuntu 20.04.1 LTS
Memory	31.3 GB
Processor	Intel Corei7-6700K CPU @ 4.00 GHz x8
Graphics	GeForce GTX 1080 Ti (11GB)
CUDA	10.2
cuDNN	8
Algorithm/ Framework	YOLO v4, Darknet

(4) Evaluation of models

We evaluated the trained models with the test images at every 1,000 iterations for average detection rate and mean Average Precision (mAP). The detection rate refers to the percentage of plants detected by the model in each image (Eq.1). Mean average precision (mAP) includes several important indexes; Intersection of Union (IoU), precision, recall and F-1 score. IoU calculates the overlap ratio between the boundary box of the prediction and ground-truth. Precision is the ratio of true positive (TP) or predictions that correspond to the ground truths to the total number of predictions made while Recall refers to the ratio of true predictions and the total of the ground truth positives. Precision and Recall were calculated by equations 2 and 3 where P is precision; R is recall; TP is the number of correctly detected tillers; $TP + FP$ represents the total

number of detected tillers; $TP + FN$ represent the total number of actual tillers (ground truth).

Equation 1

$$\text{Detection rate} = \frac{\text{Number of Plants Detected in Image}}{\text{Total Plants in Image}} \times 100$$

Equation 2

$$\text{Precision} = \frac{\text{True Positive (TP)}}{\text{True Positive (TP)} + \text{False Positive (FP)}}$$

Equation 3

$$\text{Recall} = \frac{\text{True Positive (TP)}}{\text{True Positive (TP)} + \text{False Negative (FN)}}$$

The mean average precision (mAP) is simply the mean of the average precision (AP) for all the classes. The average precision (AP) is generally defined as the area under the precision recall curve (P-R curve) and is calculated as the weighted mean of precisions achieved at each threshold with the increase in recall from the previous threshold used as the weight. For evaluations of the models with the test data set, the IoU threshold was set at 50%.

3. RESULTS & DISCUSSION

Active tillering refers to the growth period when tillers emerge in rapid succession (Smith & Dilday, 2003). During this stage the plant is continuously producing tillers some of which will develop into productive tillers and others which would die off after peak or maximum tillering. Based on the manually collected data, the number of tillers per plant at this stage ranged from 2-37.

Table 4 Results of model evaluations for detecting tiller numbers at active tillering stage

Model	# Train Images	# Classes	# Test Images	# Training Iterations	Detection Rate	Precision	Recall	F1-score	Avg. IOU	mAP
Actual Tiller		37		2000	86.1	0.11	0.12	0.11	8.17	9.17
Grouped 2		18		2000	85.4	0.25	0.28	0.26	19.43	15.16
Grouped 3	223	12	17	6000	93.03	0.32	0.35	0.33	24.86	22.21
Grouped 4		9		3000	95.2	0.37	0.41	0.39	29.22	33.4
Grouped 5		8		1000	96.1	0.52	0.6	0.56	36.87	36.04
Dist.		3		2000	100	0.64	0.76	0.69	48.46	67.53

The models trained to detect actual tiller numbers had low performance (mAP 9.17). Among the grouped class ranges, *Grouped5* (class range of 5 tillers) had the best performance (mAP 36.04). The results suggest that these models cannot accurately distinguish the difference in groups of tillers. The models annotated based on the distribution of tiller number per plants gave the most promising results with precision 0.64, recall 0.76, and mAP 67.53. The class ranges of this model is below 10 tillers, 11-17 tillers and above 17 tillers. Examples of detections by all models are shown in Figure 1.

Detection rate refers to the percentage of plants detected by the model in each image. Detection rate for all models were generally good and tend to increase as the number of class decreased. Given the size of the data set remained the same, as the number of classes decreased, the number of training images per class increased.

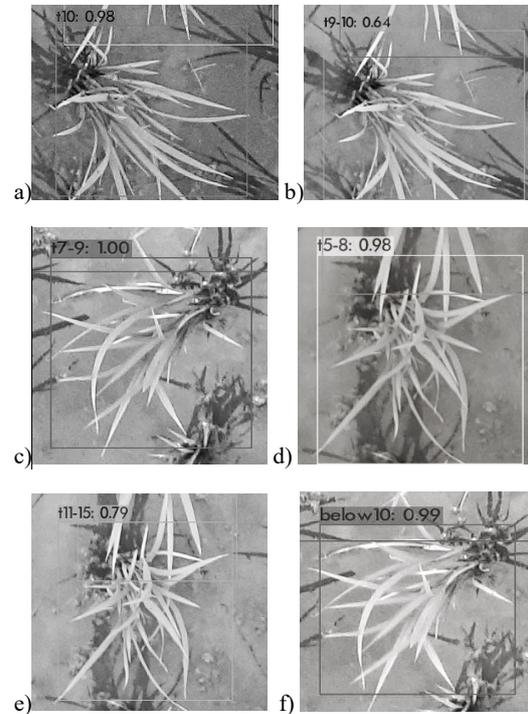


Figure 1 Examples of detection by models at active tillering for tiller detections; a) Actual Tiller (mAP 9.17); b) Grouped 2 (mAP 15.6); c) Grouped 3 (mAP 22.1); d) Grouped 4 (mAP 33.4); e) Grouped 5 (mAP 36.04) and f) Dist. (mAP 67.53)

4. DISCUSSION

In this work, we used deep learning to determine the tiller number range from infield images and obtained encouraging results. Of the three approaches to class ranges, the approach based on distribution gave the best results (mAP 67.5). This can be attributed to the wider class range resulting in the easier differentiation of plant growth level and more training objects per class. The information provided by this approach to class range, though not as detailed as the other approaches, can be used to identify areas in the field where growth is no, so the necessary measures can be applied. –Insufficient training data for some classes led to unbalance in the data set which would have affected the performance of the models. This will have to be addressed in future work. Deep learning and computer vision has been increasingly being used in detecting various aspects of rice growth; heading date determination (Desai, Balasubramanian, Fukatsu, Ninomiya, & Guo, 2019), panicle segmentation (Xiong et al., 2017), panicle counting (Zhou et al., 2019), density estimation (Liu,

Lu, Li, & Cao, 2020), limited attention has been focused on tiller detection. Deng et al., (2020) used Faster R-CNN to detect the productive tillers in rice with relative high accuracy. The approach, however, focused on the detecting the productive tillers at maturity, requiring the plant to be harvested to expose the cross sections of the tillers, thus there was only one class to be detected; the cross section of the tillers. On the other hand, our approach detects the range of tillering based on the whole plant during the different growth phases of tillering. Earlier efforts Constantino et al., (2018); Wu et al., (2019); W. Yang et al., (2011b); Zhifeng et al., (2016) approached tiller detection from the perspective of high throughput systems for plant breeding programs, targeting potted plants, or plants at maturity. However, our approach targets the infield determination of tillering at three phases; early, active and peak tillering, with the view of providing information to guide management practices for the achievement of optimum yields.

CONCLUSION

In this study we explored deep learning as an alternative method to detect tillering in rice. We examined tiller detection at three class ranges; actual, grouped and distribution at the active tillering phase of rice growth. Our results show that the models developed could not accurately distinguish tillers at the individual level. However, promising results were obtained at the wider class range (Dist.). The lack of enough data across all of the class ranges was a limitation that affected the performance of the models and will have to be addressed in future work. The results achieved is encouraging as it offers the potential of providing information of the tillering status of plants over the entire field, which can be used to guide management practices.

ACKNOWLEDGMENT

Gratitude is expressed to the Worldwide Japan Food Platform (W-JFoP) Consortium for providing the necessary resources and technical support for the execution of this research.

REFERENCE

- Al-Khatib, K., Linqvist, B., Swett, C., Espino, L., Leinfelder-Miles, M., Brim-Deforest, W., & Mckenzie, K. (2018). *California Rice Production Workshop*. (M. Quinton, Ed.). University of California Agriculture and Natural Resource.
- Bian, J., Zhu, G., Zhu, C., Peng, X., Li, C., He, X., ... Yan, S. (2015). Molecular dissection of developmental behavior of tiller number and the relationship with effective panicle using indica-japonica introgression lines in rice. *Molecular Breeding*, 35(3).
- Bochkovskiy, A., Wang, C.-Y., & Liao, H.-Y. M. (2020). YOLOv4: Optimal Speed and Accuracy of Object Detection. Retrieved from <http://arxiv.org/abs/2004.10934>
- Constantino, K. P., Gonzales, E. J., Lazaro, L. M., Serrano, E. C., & Samson, B. P. (2018). Towards an automated plant height measurement and tiller segmentation of rice crops using image processing. *Mechatronics and Machine Vision in Practice* 3, 155–168.
- Deng, R., Jiang, Y., Tao, M., Huang, X., Bangura, K., Liu, C., ... Qi, L. (2020). Deep learning-based automatic detection of productive tillers in rice. *Computers and Electronics in Agriculture*, 177(August), 105703.
- Desai, S. V., Balasubramanian, V. N., Fukatsu, T., Ninomiya, S., & Guo, W. (2019). Automatic estimation of heading date of paddy rice using deep learning. *Plant Methods*, 15(1), 1–16.
- Fukushima, A. (2012). Yield potential of high-yield rice varieties in the tohoku region of Japan. *Japan Agricultural Research Quarterly*, 46(3), 199–204.
- Liu, L., Lu, H., Li, Y., & Cao, Z. (2020). High-Throughput Rice Density Estimation from Transplantation to Tillering Stages Using Deep Networks. *Plant Phenomics*, 2020, 1–14.
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016-Decem*, 779–788.
- Smith, C. W., & Dilday, R. H. (2003). *Rice: origin, history, technology, and production*. John Wiley & Sons Inc.
- Wu, D., Guo, Z., Ye, J., Feng, H., Liu, J., Chen, G., ... Yang, W. (2019). Combining high-throughput micro-CT-RGB phenotyping and genome-wide association study to dissect the genetic architecture of tiller growth in rice. *Journal of Experimental Botany*, 70(2), 545–561.
- Xiong, X., Duan, L., Liu, L., Tu, H., Yang, P., Wu, D., ... Liu, Q. (2017). Panicle-SEG: A robust image segmentation method for rice panicles in the field based on deep learning and superpixel optimization. *Plant Methods*, 13(1), 1–15.
- Yang, W., Xu, X., Duan, L., Luo, Q., Chen, S., Zeng, S., & Liu, Q. (2011). High-throughput measurement of rice tillers using a conveyor equipped with x-ray computed tomography. *Review of Scientific Instruments*, 82(2), 025102.
- Zhifeng, H., Liang, G., Chengliang, L., Yixiang, H., & Qingliang, N. (2016). Measurement of Rice Tillers Based on Magnetic Resonance Imaging. *IFAC-PapersOnLine*, 49(16), 254–258.
- Zhou, C., Ye, H., Hu, J., Shi, X., Hua, S., Yue, J., ... Yang, G. (2019). Automated counting of rice panicle by applying deep learning model to images from unmanned aerial vehicle platform. *Sensors (Switzerland)*, 19(14).

エチオピアでの米のポストハーベストと農作業について

片平光彦*

Investigated on Agricultural Machinery and Post-Harvest Technology in Ethiopia

Mitsuhiko KATAHIRA*

Abstract

In Ethiopia, rice consumption is expanding. However, it is increasing rice imports that domestic rice production is insufficient for the demand. Thus, there is a need to improve the productivity of domestic rice. Therefore, since 2015, JICA has a EthioRice Project that contributes to the development of rice research and the rice industry in Ethiopia through the National Rice Research and Training Center (NRRTC). I investigated post-harvest and pre-harvest of rice cultivation at Federal Agricultural Research Centers under the Ethiopian Institute of Agricultural Research (EIAR) and NRRTC in Fogera, Amhara Province, from November 25 to December 20, 2019. Plowing was used long floor type hoe which was pulled by a cow. The plowing depth is about 15cm, and ploughing depth is increasing by plowing frequency. Amount of hulling, Satake type milling machine, had 390 to 580kg / h, respectively. The hulling recovery was around 80%, the hulling rate were 97-99%, broken rice rate were 15-36%, and the rice husk contamination rate were minimal. NERICA4 had more broken rice than Ediget. In NERICA4 and Ediget, the moisture contents were 12.6%, which were lower than 15% at Japanese standard. Thousand grains weight of NERICA4 is lighter than Ediget, and thickness of rice grain is thin, too. Fissures occurred around 50% in NERICA4. This reason is over-drying and thin grain thickness. The Satake type rice milling machine, which has rice hulling and rice milling simultaneously, has a friction type rice milling implement located at the lower part of the rice milling machine. The degree of milling is adjusted with the weight and weight positions attached to table 1. The milling rate of normal setting was 83%, and the milling rates that changed weight and weight position were 75-80%. These milling rates, compare to 90% in Japan, were so small. That results shows too much cut down on rice. Decreasing the milling rate as broken rice rate increase.

[Keywords] Ethiopia, agricultural machinery, post-harvest technology, hulling, milling

1. 緒言

エチオピアでは、米の消費が拡大しているが、国内での米生産はその需要に対して不足していることから輸入が増加しており、国産米の生産性改善が求められている。そこで、JICA では2015年から国立イネ研究研修センター (National Rice Research and Training Center, NRRTC) 強化プロジェクト「EthioRice Project」を開始し、エチオピアでのイネ研究とコメ産業の発展に寄与する事業を推進している。

エチオピアの主要作物は穀類 (全体量の65%) であり、そのうち水稲は Amhara, Oromya, Tigray, SNNP, Somali and Gambella の各州で栽培されており、全穀物生産量に占める割合が 0.5%と少ない現状にある (トウモロコシ:26.8%、テフ:17.6%、ソルガム:16.1%、小麦:15.7%、大麦:7.2%)。また、生産者は栽培規模 2ha を境にして大規模、小規模農家に区分されており、大規模農家が 10%、小規模農家が 90%の構成で、小規模農家の大部分が天水農業である。水稲作への農業機械の導入は、播種機と脱穀機を中心とした機械化が要望されている。

本報ではエチオピア農業研究機構 (Ethiopian Institute of Agricultural

Research, EIAR) 傘下の連邦立農業研究センターのひとつで、Amhara 州の Fogera 平原にある前記した NRRTC を中心に米生産での農作業技術体系、ポストハーベスト関連技術に対して 2019 年 11 月 25 日から 12 月 20 日にかけて調査を行ったので報告する。本報は JICA と EthioRice Project からの補助で実施したものであり、関係各位に謝意を表す。

2. 調査内容

(1) 耕起作業の状況

エチオピアの Fogera 地区の生産者は、主に耕起を牛が牽引する長床犁で実施していた (図 1)。耕起は碎土と耕深を確保するため、約 30a のほ場を 2 日で 2 回実施する。犁による耕起の耕深は約 15cm であり、耕起回数を増やすことで徐々に耕深を深くする耕法であった。使用している長床犁は深耕に適さないものの、操作時の安定性に優れるため生産地で長年利用されている。

現地での耕うん・耕起の改善については、現状の牛耕の場合耕深を確保するために数回の作業が必要であり、30~40PS 級トラクタ



図1 Vertisol 土壌での長床犁による牛耕



図2 Fogera 地区生産者所有の長床犁

の利用が有効である。現地の農業機械メーカーでは、中国製の10～15PS級の歩行トラクタをモデルに製造しているが、機体質量が軽いため、現地土壌のVertisolでの耕うんに適用することが難しい。

(2) 収穫・乾燥と脱穀

収穫は鎌を用いた手刈りで、藁などで結束せずにほ場に直接置くものであった。刈り取られた稲は、ほ場で1日乾燥した後に集められ、図3に示すように円形状に穂を内側にして積み上げて約1日乾燥するテンパリングの2段階で行われており、穀粒内の水分の均一化を図っている。脱穀は乾燥した稲株を地面に置き、牛による踏みつけ(図4)や棒で叩いて行う。脱穀性能は、生産者への聞き取りで満足できるとの回答であったが、回収時にはロスが発生しており、EIARの研究者もその詳細について調査の必要があるとの認識であった。なお、選別は手作業による風選である。

(3) 現地精米の状況

Fogera地区の精米業者は、エンゲルバーグ式の籾摺り精米機を使用しており、精米回収率が65～75%であった。碎米は発生するが、それらは現地の主食であるインジェラに混入して利用するため、特



図3 Fogera 地区での収穫した稲の二次乾燥



図4 牛を使った脱穀

注：図3の乾燥した藁の円柱を崩して壁を作り、その内部に藁を敷き詰めて脱穀を行う。



図5 Fogera 地区精米業者のエンゲルバーグ式精米機

に問題になっていない。業者は精米機自体に特に不満がないとの認識で一致していた。なお、別の精米業者は、図6に示すサタケ製籾摺り精米機、精米用の振動選別機を導入しており、碎米と精米を分離して出荷することもあるとのことであった。

精米に関し、業者の回収率は前記したとおり65～75%となっている。すなわち、籾は籾摺り精米機に投入され、籾殻を20%、糠を5～15%除去(搗精率：85～95%)して出荷されていると予想される。なお、エンゲルバーグ式では風選がないため、未熟粒もそのまま整粒として排出されるため、出荷される精米に未熟粒なども含まれている可能性がある。サタケ式は籾すり機、風選、精米の順序で加工されるため、未熟粒は2番口から排出されることからエンゲルバーグ式と比較して精米時の状態が良好といえるが、業者からはそれについて特に意見がなかった。



図6 サタケ式籾摺り精米機 (NRRTC 所蔵)

(4) 籾摺り精米機を用いた現地品種での籾摺り調査

NRRTC では、JICA の支援で前記した図 6 に示す籾摺り精米機 (サタケ, SB10D) が導入されており、現地への指導も行っていた。現地では、籾摺り精米機の性能調査を行った。

籾摺り試験での供試品種は NERICA4、Ediget (日本名：日本晴) の 2 品種で、それぞれ 17kg と 18kg を用いた。調査項目は、籾摺り量 (kg/h)、玄米回収率 (%)、脱ぶ率 (%)、割れ米混入率(%), 籾殻玄米比率、胴割れ率(%), 玄米千粒重(g)、含水率(%wb)である。

両品種での籾摺りの状況を図 7、性能試験の結果を表 1 と 2 にそれぞれ示す。籾摺り精米機は、籾摺り量が 390~580kg/h となり、品種間で差があった。籾摺り性能は、玄米の回収率が約 80%、脱ぶ率が 97~99%、一番口での碎米混入率が 15~36%、籾殻混入率が極少であった。NERICA4 は一番口に含まれる碎米が Ediget よりも多かった。NERICA4 と Ediget では、調査時の水分がいずれも 12.6% であり、日本の籾摺り時水分 15%より低く、籾摺り時点として過乾燥な状態であった。玄米千粒重は NERICA4 が Ediget よりも軽く、

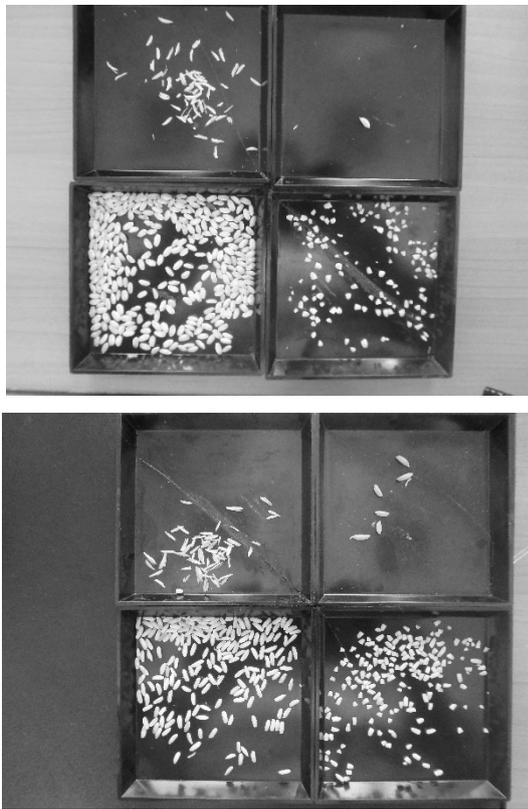


図 7 籾摺り状況 (上段：Ediget 下段：Nerica4)

表 1 供試品種の特性

Varieties	Grain Weight (g/1000grain)	Moisture (%WB)	Fissure (%)	Paddy components(%)	
				Brown rice	Husk
Nerica4	21.0	12.6	48.7	80.8	19.2
Ediget	24.8	12.6	9.2	78.1	21.9

表 2 籾摺り精米機の籾摺り性能

Varieties	Hulling capacity (kg/h)	Hulling recovery (%)	Hulling rate (%)	Crack rate (%)
Ediget	573	80.0	99.4	14.8

充実度が低い。胴割れは NERICA4 が約 50%発生していた。これは、過乾燥と粒厚の薄さが要因といえる。籾殻と玄米の比率は、両品種とも玄米 80%、籾殻 20%となっており、Japonica 種と同等であった。籾摺り時の碎米は、主に原料の胴割れが要因といえる。なお、脱ぶ率は日本の基準である 90%より高いため、ロール開度を広げて脱ぶ率を現状よりも低下させる必要がある。

(6) 精米試験

NRRTC に導入されているサタケ製籾摺り精米機 (サタケ, SB10D) を用いて精米試験を行った。供試品種は Ediget (水分 13.4% wb)、供試サンプル量が 6kg×3 であった。試験区は精米機に付属する錘と錘の位置を 3 段階に組み合わせて設定し、それぞれの搗精率 (%) を調査した。籾摺り精米機は本体の下部に精米ユニットが位置してお

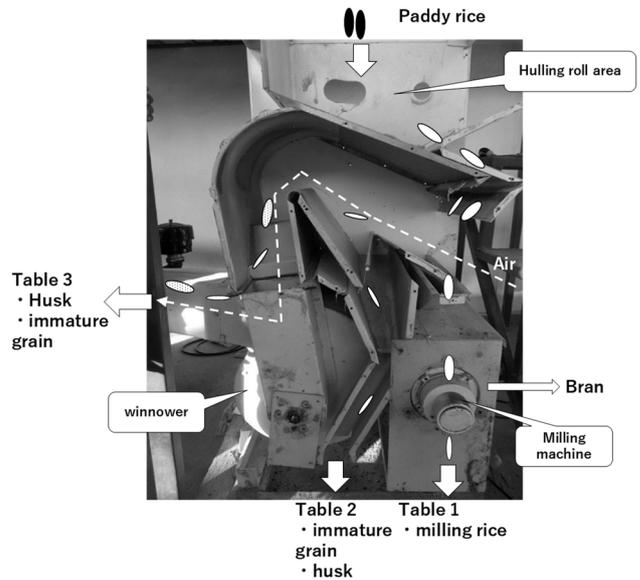


図 8 籾摺り精米機の内部構造

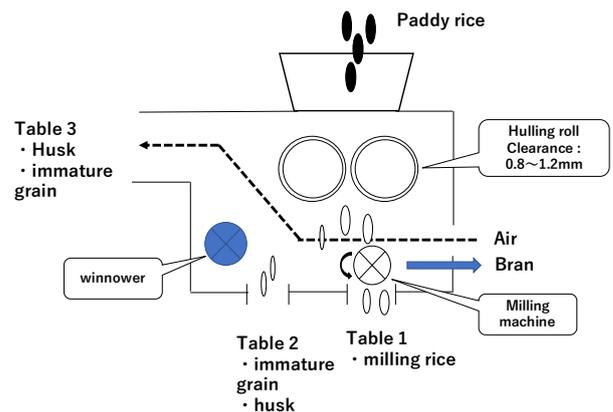


図 9 籾摺り精米機の動作模式図

表 3 籾摺り精米機での精米性能 (品種：Ediget)

TEST	weight (g)	position	brown rice (kg)	milling rice (kg)	bran (kg)	milling rate (%)
TEST1	300	bottom	6.0	5.0	1.0	83.3
TEST2	300	top	6.0	4.5	1.5	75.0
TEST3	600	bottom-top	6.0	4.8	1.2	80.0

*1: Variety is Ediget, Moisture contents are 13.4(%wb)

り、籾摺りと精米を同時に行う機構(図8、9)になっている。籾摺り方式は摩擦式で、搗精程度を一番口に付属する扉の錘で調整する。

試験結果を表3に示す。通常設定(test1)の搗精歩合は83%、錘位置を変えた際の搗精歩合は75~80%で変化した。搗精歩合は日本の90%と比較して小さく、削りすぎの傾向にあった。搗精率を大きくすると砕米の発生も増えるため、300g以下の錘を使用して搗精歩合を90%程度に調整することが必要である。

精米では、品種と水分や胴割れの状態、10%以上の搗精率によって割れ米が多く発生する。特に、NERICA4は玄米の幅が細く、胴割れも多いため割れ米が多い。今後の対応として、機械面では脱ぶ率と搗精率の調整、原料面で適期収穫、水分14%での貯蔵が求められる。

(7) NRRTC の試作 Reaper

NRRTC での Reaper での試験状況を図10に示す。



図10 NRRTC で開発した Reaper による収穫作業

収穫機はディーゼルエンジンを搭載した歩行管理機を改良したもので、4条刈りのヘッダ(取り外し可)で刈り取りを行う。収穫機は機体の全長が長いので、収穫前に旋回半径を確保するため角部を手刈りする必要がある。また、ほ場の基盤が軟弱な部分では車輪に滑りが発生し、作業できないことがある。

乗用収穫機は現状の予乾体系に合致しているが、機械の操作性に問題がある。また、作業時の走行速度は約1m/s程度であるが、操作性を鑑み速度を低下して利用することが必要である。

3. 現地の課題

NRRTC での農業機械研究系の研究課題は、ほ場機械として耕うん機や収穫機の導入、収穫後調製機械として精米機や貯蔵庫の研究、籾のパーボイル加工、籾穀バーナー(図11)といった課題が提案されており、概ね現状にあったものであった。ただし、課題提案に際しては現状で問題になっていることのデータを示し、それを基に改善後の数値目標を記載することが求められる。

今後の現地での研究課題としては、ほ場機械として現地土壌に対応した機械耕うん作業体系の確立、乾田条播機の開発が考えられる。収穫後調製関連としては、現地気候に対応した籾(玄米)の最適貯蔵条件、畜力脱穀などによるポストハーベスト工程でのロスの調査、砕米の選別に用いる選別手法の開発が求められる。その他、機械の導入に際し、研究員は生産者への指導も考慮し、機械の調製・メンテナンスに関する知識習得も必要である。研究課題の策定と実行に際し、研究員は生産現場で優先される問題を特定し、それに対するデ



図11 NRRTC の研究者が開発した籾穀バーナー

注：この籾穀バーナーは籾のパーボイル加工に利用される。



図12 NRRTC の農業機械系研究者

ータを基にした現状把握、改善すべき目標数値の策定、課題解決に向けた実行と確認が連続する研究計画立案能力を高める必要がある。また、研究員には生産現場や研究ほ場へ十分に足を運ぶとともに、普及や企業との関係者との連絡を密にして、信頼関係が構築できるように心がけることを求める。

機械の整備や試作に関し、NRRTC では小型の切断機、溶接機に対応している。そのため、機械のメンテナンスや試作機の改良に支障がある。機械のメンテナンスについては、首都にある EIAR の Melkasa センターと同様に研究アシスタントに対する技術研修の実施も必要である。試作用機器としては、はじめに工作器具を設置する作業台や定盤を設置し、次いで機器を運搬するクレーンかチェーンブロック、鋼材を曲げるベンダー、切削を行う旋盤や卓上フライス盤の導入を検討すべきである。

最後に人材の育成に関し、研究員は ICT リテラシーや資料作成の能力が高く、新技術の取得に対する意欲も高い。ただし、実際の実験でのデータの取得方法や調査手順など基本的な操作について知識が不足している面がある。今後はこれらの課題のサポートや新技術の取得について日本側との交流を進めていくことが必要といえる。

アイマークレコーダーを利用した家畜状態把握時の家畜管理者の 注視特性

今野真輔*・比留間秀哉**・堀口健一***・片平光彦***

Gaze Characteristics of Livestock Farmer during Grasping the State of Livestock using Eye-Mark Recorder

Shinsuke KONNO*・Hideya HIRUMA**・Kenichi HORIGUCHI***・Mitsuhiko KATAHIRA***

Abstract

The number of livestock farmer is decreasing as a result of retirement due to aging of the farmer and lack of the successor. Therefore, livestock farmers have more domestic animals. Livestock managers generally check state of animal by sight. It is necessary to have the observant eye cultivated by a lot of experience to accurately grasp the condition of livestock. So, it is not easy for inexperienced livestock managers in order to accurately grasp the condition of livestock. In this study, we investigated the gaze characteristics of skilled livestock managers using an eye-mark recorder with the aim of helping beginners to improve their skills. The gazing point was measured by having the examinees wear eye-mark recorder (EMR9, nac Image Technology Inc.) and observing the estrus state of cow and the health state of calf. The number of gazing points, gazing time and gazing time per one gazing point were calculated for each gaze item using the software for analyzing and aggregating gaze target (EMR-dTarget for 9Pro X Ver.4.0, nac Image Technology Inc. / Emovis Corp.) The skilled livestock manager focused on cow's body and rump depending on condition of the cow and calf's face. The skilled livestock manager had precise observing points and tended to spend time observing points which required attention.

[Keywords] calf, cow, eye-mark recorder, livestock management, skilled livestock manager

1. 緒言

畜産業界は従事者の高齢化が進むと同時に後継者不足に直面し、畜産農家数の減少と飼養規模の大規模化が進んでいる(農林水産省, 2020)。飼養規模が大きくなると、家畜個体の状態を正確に把握し、健康を維持することが難しくなる。また、家畜の飼育には発情や体調といった動物の状態を正確に把握することのできる観察眼が大切であり、その観察眼を養うには豊富な経験や直感が必要となる。

一般的に家畜管理者は発情や体調を把握する際、外見の状態や家畜行動を目視で確認する。牛の繁殖管理では発情を見逃さずに発見し、適切なタイミングで人工授精を行うことが大切である。しかし、近年、繁殖牛の受胎率は低下しており(家畜改良事業団, 2020)、農家経営に影響を与えている。また、子牛は成牛と比較して体調を崩しやすいため、飼育管理面で注意が必要となる。体調を崩した子牛は、重症化すると発育停滞や死亡する場合もあり、重症化を防ぐための早期発見が重要である。子牛の体調管理の指標は、目や鼻、糞便の状態などが示されている(酪農ヘルパー全国協会, 2009)。しかし、これらの指標はいずれも機微の変化であることが多いため、経験年数が浅い家畜管理者にとって子牛の健康状態を正確に判断

することが難しい現状にある。農業分野では ICT を活用した技術継承やマニュアル化が検討されている(農林水産省, 2020)。また、スポーツや看護現場などでは初心者への技術向上に役立てることを目的に、アイマークレコーダーを利用し熟練者と初心者の注視特性を分析している(中田ら, 2016; 大黒ら, 2017)。

本報では、アイマークレコーダーを使用して熟練家畜管理者の注視特性を明らかにし、家畜管理初心者の技術向上に役立てることを目的に、家畜観察時の注視特性を検討した。

2. 材料と方法

(1) 注視点の計測

注視点の計測は、2020年1月に山形大学農学部附属やまがたフィールド科学センター高坂農場内の牛舎で実施した。被験者にアイマークレコーダー(EMR9, ナックイメージテクノロジー)を装着させ、成雌牛の発情状態と哺乳期子牛の健康状態を観察させた。被験者は山形大学農学部附属やまがたフィールド科学センターの技術職員に依頼した。計測時、被験者Aは畜産経験2年、被験者Bは畜産経験30年である。観察対象の牛は成雌牛3頭(成雌牛1:発情数日前、成雌牛2・3:分娩後1か月以内で発情未確認)と哺乳

* : 岩手大学大学院連合農学研究科(山形大学配属) 山形県鶴岡市若葉町1-23

** : 株式会社エモヴィス 東京都台東区松が谷3-20-12 ネバーランド上野松が谷

*** : 山形大学農学部 山形県鶴岡市若葉町1-23

表1 発情直前の成雌牛の観察における注視特性

		被験者A	被験者B
観察時間(s)		67.0	31.8
注視回数	Face	27	10
	Body	17	9
	Rump	17	7
	Total	61	26
注視時間(s)	Face	25.0	7.9
	Body	10.0	7.2
	Rump	18.6	8.3
	Total	53.6	23.4
1注視点あたりの注視時間(s)	Face	0.93	0.79
	Body	0.59	0.80
	Rump	1.09	1.18
	All	0.88	0.90

期子牛2頭(2頭飼いで計測時, 体調良好)とし, 測定前に観察対象の牛を被験者に伝えた。なお, 成雌牛1の発情は獣医による診療で数日の間に発情が起こる可能性が伝えられていた。計測後, 観察時に注意したポイントや観察時の牛の状態に関してインタビューを行った。

(2) 解析方法

注視データの解析には注視ターゲット解析・集計ソフトウェア(EMR-dTarget for 9Pro X Ver.4.0, ナックイメージテクノロジー/エモヴィス)を使用した。ソフトウェアは, パラメーター(注視点判定X値: 5, 注視点判定Y値: 15, 注視点判定通りフレーム数: 5, 注視時間閾値0.2s)を設定し, 抽出された注視点1つ1つを項目別に分類し, 注視点数, 注視時間, 1注視点あたりの注視時間, 1注視点の注視時間別発生頻度を算出した。注視項目は成雌牛が「Face」, 「Body」, 「Rump」, 哺乳期子牛が「Face」, 「Body」, 「Other」とした。なお, 「Other」は牛床や赤外線ヒーター, 糞, 残飼など牛体以外で牛の状態や飼育環境に関係するポイントとした。

3. 結果と考察

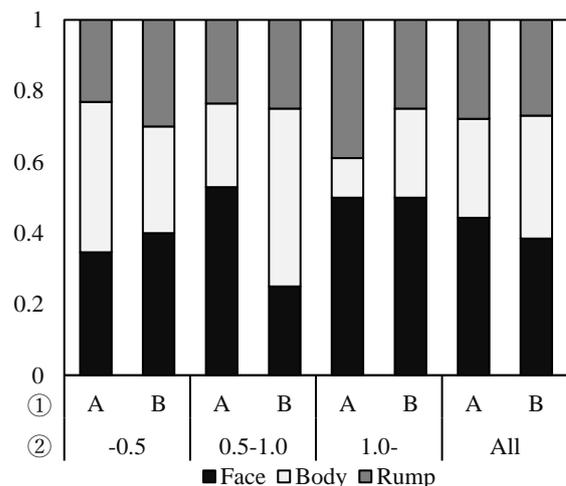
(1) 発情直前の成雌牛

表1に発情直前の成雌牛(成雌牛1)の観察における注視特性を示す。観察時間は被験者Aが67.0秒, 被験者Bが31.8秒となり, 被験者Aが長く時間観察していた。1注視点あたりの注視時間は, 「Face」は被験者Aが0.93秒, 被験者Bが0.79秒であったのに対し, 「Body」は被験者Aが0.59秒, 被験者Bが0.80秒であった。被験者Aが体より顔を注視していたのに対し, 被験者Bは顔より体を注視していた。発情直前の成雌牛の観察における各被験者の1注視点の注視時間別発生頻度の項目別割合を図1に示す。0.5-1.0秒間の被験者間では, 被験者Aが「Face」の割合が高く, 被験者Bが「Body」の割合が高くなった。被験者Bは, 体の汗の有無を注意していたことが影響したと考えられる。一般的に, 発情時の牛は体温が上がる傾向にあり, 冬場に舎内飼育をしている場合に背中

の発汗がみられる。被験者Bはこのポイントを被験者Aよりも重視していた。

(2) 分娩後発情未確認の成雌牛

分娩後発情未確認の成雌牛(成雌牛2・成雌牛3)の観察における注視特性を表2に示す。なお, 表中の数値は2頭の合計を示す。観察時間は被験者Aが56.8秒, 被験者Bが60.3秒となり, 同程度の観察時間となった。1注視点あたりの注視時間は, 「Rump」で被験者Aが0.72秒, 被験者Bが1.09秒となり, 被験者Bが被験者Aよりも注視していた。分娩後発情未確認の成雌牛の観察における各被験者の1注視点の注視時間の注視時間別発生頻度の項目別割合



※①: 被験者

②: 1注視点の注視時間(s)

図1 発情直前の成雌牛の観察における各被験者の1注視点の注視時間別発生頻度の項目別割合

表2 分娩後発情未確認の成雌牛の観察における注視特性

		被験者A	被験者B
観察時間(s)		56.8	60.3
注視回数	Face	27	18
	Body	27	34
	Rump	15	9
	Total	69	61
注視時間(s)	Face	18.3	9.4
	Body	15.2	19.4
	Rump	10.8	9.8
	Total	44.2	38.6
1注視点あたりの注視時間(s)	Face	0.68	0.52
	Body	0.56	0.57
	Rump	0.72	1.09
	All	0.64	0.63

を図2に示す。1.0秒以上の被験者間では、被験者Bで「Rump」の割合が高くなった。

被験者Bは「Rump」の注視回数が少ないが、1回の注視でより長い時間観察しており、それはインタビュー結果から、特に陰部の状態を確認していたことが分かった。

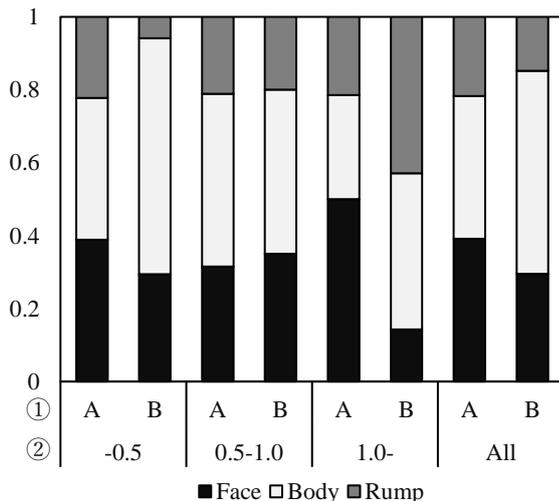
(3) 哺乳期子牛

表3に哺乳期子牛の観察における注視特性を示す。観察時間は被験者Aが38.7秒、被験者Bが148.6秒となり、被験者Bが長い時間観察していた。これは被験者Bが子牛をなでたり、子牛の行動を観察したりしていたためである。「Face」について、被験者Bは被

験者Aより注視回数が多く、注視時間と1注視点あたりの注視時間が長くなった。哺乳期子牛の観察における各被験者の1注視点の注視時間の注視時間別発生頻度の項目別割合を図3に示す。1.0秒以上の被験者間では、被験者Bで「Face」の割合が高く、顔の状態をより注意して観察していたと考えられる。インタビューでは、「鼻の状態はすぐ把握できるが、目は時間をかけて観察しないと状態が把握できない」と話しており、それが結果に影響を与えた。

(4) 観察ポイント

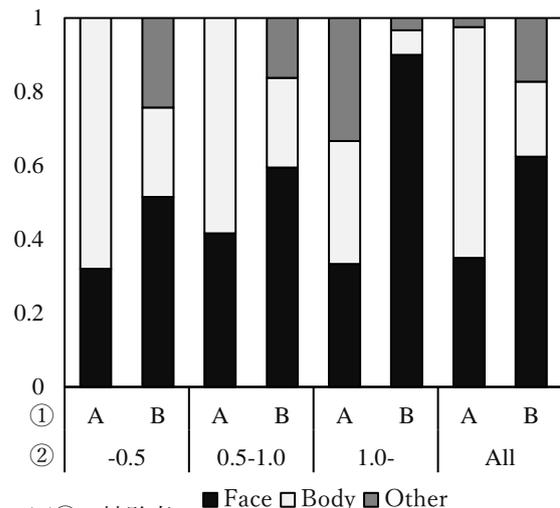
インタビューから得られた各被験者の成雌牛および哺乳期子牛の観察時の注意ポイントを表4に示す。被験者Aと被験者Bの回



※①：被験者

②：1注視点の注視時間(s)

図2 分娩後発情未確認の成雌牛の観察における各被験者の1注視点の注視時間別発生頻度の項目別割合



※①：被験者

②：1注視点の注視時間(s)

図3 哺乳期子牛の観察における各被験者の1注視点の注視時間別発生頻度の項目別割合

表3 哺乳期子牛の観察における注視特性

		被験者A	被験者B
観察時間(s)		38.7	148.6
注視回数	Face	14	83
	Body	25	27
	Other	1	23
	Total	40	133
注視時間(s)	Face	7.7	82.8
	Body	12.3	16.4
	Other	1.1	11.1
	Total	21.1	110.3
1注視点あたりの注視時間(s)	Face	0.55	1.00
	Body	0.49	0.61
	Other	1.12	0.48
	All	0.53	0.83

表4 各被験者の成雌牛および哺乳期子牛の観察時の注意ポイント

		被験者A	被験者B
成雌牛	Face	目（とろんとしているか）	目（うるっとしているか）
	Body	-	背中の汗
	Rump	粘液	粘液
哺乳期子牛		目（とろんとしていないか）	目（とろんとしていないか，焦点が合っているか）
	Face	鼻（ぬれているか）	鼻（ぬれているか）
		耳（立っているか）	耳（立っているか）
	Body	便の付着	-
	Other	-	便・残飼

答が一致したのは、被験者 A と被験者 B が普段の飼育管理で牛の状態等の意見交換を盛んに行っており、観察時注意しているポイントも共有していたためである。普段の観察方法に関し、被験者 A は朝昼夕 3 回同様の方法で観察を行っており、被験者 B は朝 1 回目の観察で全体の状況を把握したあと、それ以降の観察では朝 1 回目の観察で気になったポイントを中心に観察を行う。今回の測定は、朝給餌後の午前中か午後に行ったため、被験者 B の注視データが観察方法の影響を受けて、気になったポイントを中心に観察していたと考えられた。

4. 摘要

アイマークレコーダーを利用して、成雌牛の発情状態および哺乳期子牛の健康状態の観察における家畜管理者の注視特性を調査し、以下の結果を得た。

- 1) 熟練管理者は牛の状態に応じた観察を行っており、成雌牛の観察で牛の体や尻、哺乳期子牛の観察で顔に着目していた。
- 2) 熟練家畜管理者は、観察ポイントが明確であり、特に注意が必要なポイントに時間をかけている傾向があった。

参考文献

- 1) 農林水産省, 2020. 畜産統計,
<https://www.maff.go.jp/j/tokei/kouhyou/tikusan/index.html> (2021年1月9日閲覧)
- 2) 家畜改良事業団, 2020. 受胎調査成績,
<http://liaj.or.jp/giken/hanshoku/jyutai.html> (2021年1月9日閲覧)
- 3) 酪農ヘルパー全国協会, 2009. 新しい酪農技術の基礎と実際 実技編, 酪農ヘルパー全国協会 82-83.
- 4) 農林水産省, 2020. スマート農業の展開について,
<https://www.maff.go.jp/j/kanbo/smart/attach/pdf/index-146.pdf> (2021年1月13日閲覧)
- 4) 中田学, 河村剛光, 青葉幸洋, 濱野礼奈, 菅波盛雄, 2016. バレーボールにおける注視点の特性, バレーボール研究, 18 (1), 12-18.
- 5) 大黒理恵, 齋藤やよい, 2017. 熟練看護師のベッドサイド場面観察時の注視の特徴, 日本看護技術学会誌, 15 (3), 218-226.

データセットに含むエダマメ品種の違いによる 物体検出 AI のエダマメ外観品質分類精度の変化

森智洋* ・ 片平光彦**

Effects on Accuracy of Object Detection AI by Difference in Green Soybean Varieties Included in Dataset

Tomohiro MORI* ・ Mitsuhiro KATAHIRA**

Abstract

Almost all farmers who cultivate green soybeans use manual sorting, with a work efficiency of 12 kg/h, so a sorting machine must be developed for quick, accurate detection of green soybean quality. In order to develop such a sorting machine, software is needed to first detect the green soybeans and then classify their quality based on appearance. In this study, we developed an object detection AI for sorting of green soybeans based on their appearance. With the goal of establishing a method for collecting image data to create a more accurate object detection AI, we investigated the effects of 3 different varieties of green soybeans in the dataset on the accuracy of the AI. We set seven datasets; one for each individual variety with the remaining 4 comprising of different combinations of the three green soybean varieties and used these datasets to develop AI with YOLOv3. As a result, F-value of the AI trained on the dataset that included images of the green soybean varieties to be sorted were significantly higher. Therefore, it is necessary to constantly collect images and video data of the target variety to be sorted when creating an object detection AI for sorting the appearance of green soybeans.

[Keywords] object detection, deep learning, YOLOv3, sorting, variety

1. 緒言

エダマメは日本各地で栽培されており、播種作業から収穫作業までは機械化が進んでいる。しかし、収穫後の外観精選別作業はほとんどが人手によって行われており、作業能率が12kg/hと低い。そのため、作業の機械化が求められている。エダマメ外観精選別機を開発するには、エダマメの形状や色などの外観情報を基に外観品質の分類を行うソフトウェアが必要となる。

近年、ディープラーニング（以下、DL）や人工知能（以下、AI）の構造の進化により、AIの発展が著しい。AIにはいくつかの分野があり、その一つに「物体検出」がある。物体検出AIは、画像や動画の中から対象物の位置を検出して事前に定義したカテゴリーに分類する機能がある。物体検出AIは、AIに分類してもらいたい対象物が写っている画像データや動画データを収集し、それらのデータに対象物の位置座標と分類項目の情報を付与してDLで作成される。物体検出AIは精度や速度の向上を目的とした研究が活発に行われており、現在では高精度かつ高速に物体検出を行うことができる。エダマメ外観精選別機はコンベヤの上を高速で移動するエダマメをカメラで撮影し、その映像の中からエダマメの位置検出と外観品質分類を行う必要がある。そのため、物体検出AIはエダマメ外観精選別機に搭載するソフトウェアとして有効と考えられる。森ら（2019）²⁾はエダマメ外観精選別を行う物

体検出AIを作成し、物体検出AIのエダマメ外観品質分類精度が人間と同程度であることを示した。この先行研究では、AI作成時に使用したデータセットに選別対象と異なる品種の画像データを混ぜた場合に外観品質分類精度が低下した。先行研究で使用した品種は2品種のみであり、また品種の組み合わせも4つと少なかったことから、データセットに含む品種の組み合わせがAIの分類精度に与える影響を明確にできなかった。高精度な外観精選別用AIを作成するには、品種という観点から、データ収集やデータセット構築に関する方法を確立することが必要になる。

そこで、本研究ではより高精度なエダマメ外観精選別用AIを開発することを目的に、3品種のエダマメ画像データを用いて品種の組み合わせを変化させた複数のデータセットを設定し、それらのデータセットに含まれるエダマメ品種の組み合わせがAIのエダマメ外観品質分類精度に与える影響を調査した。

2. 実験方法

AI作成と精度評価に必要な画像データ用のエダマメは2019年に山形大学農学部附属高坂農場で栽培した。供試品種は「庄内三号」と「庄内一号」、「グリーン75」の3品種である。収穫後、エダマメは品種ごとに良品1項目と不良品6項目に手選別した（図1）。画像データは市販のエダマメ精選別機（株式会社ガオチャオ

* : 岩手大学大学院連合農学研究科

** : 山形大学農学部

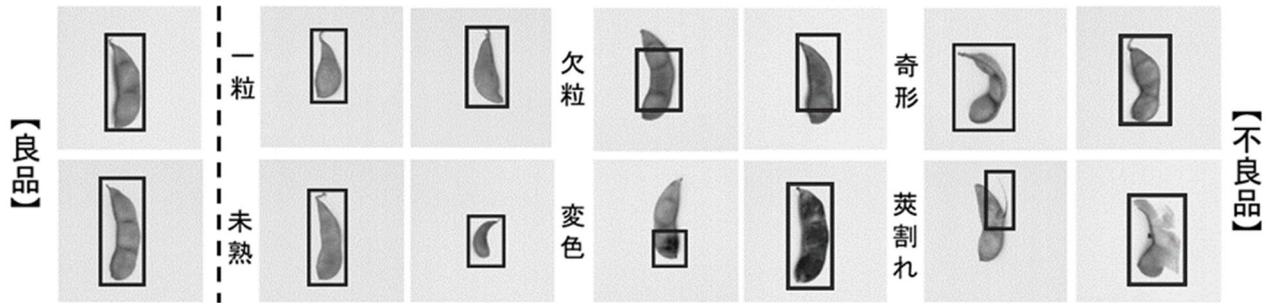


図1 エダマメの品質分類項目とアノテーションの指定範囲

エンジニアリング, PITA-EDS-mini01) の検出部に分類項目ごとにエダマメをランダムに流し込み, タイムラプス機能を用いて収集した。撮影画像サイズは1280×1024ピクセルで, 一枚の画像内に複数のエダマメが様々な角度で写っている。

DLで物体検出AIを作成するために用いる教師データの作成(以下, アノテーション)は, Microsoft社のフリーソフトウェア「VoTT-1.7.2」で行った。教師データは, AI作成用の画像データ内に写っているエダマメの位置座標と品質分類項目名を記載した注釈データである。アノテーションの指定範囲は図1に示す黒枠のとおりである。本研究で使用したAI作成用の画像データ数は, 庄内三号で1449枚, 庄内一号で1477枚, グリーン75で1665枚である。これら3品種の各分類項目のアノテーション個数を表1に示す。

AI作成に使用するデータセットに含む品種の組み合わせの違いがAIの外観品質分類精度に与える影響を調査するため, 表2に示す7種類のデータセットを作成した。データセットAとB, Cは一品種の画像データのみデータセットに含まれる。そして, データセットDとE, F, Gは複数の品種の画像データがデータセットに含まれる。AI作成用のフレームワークはDarknetを使用し, YOLOv3³⁾のAIを転移学習により作成した。用意したデータセットは7種類のため, 作成したYOLOv3のAIは計7つである。DLの学習回数は全てのAIで30000回に設定した。学習率は初期値を0.003とし, 学習回数が20,000回と25,000回に達するとそれぞれ0.0003と0.00003に減少するように設定した。AIへの画像入力サイズは768×768ピクセルに, Batchサイズを64に設定した。

各データセットで作成したAIの精度評価は, AI作成用とは異なる庄内三号の良品と不良品6項目の画像データを用いて行った。テスト画像データは分類項目ごとに画像内のエダマメの合計数が20個になるように調整したものを10反復用意した(表1)。それらのテスト画像データを各AIに入力し, 以下の3つの式で各AI・分類項目の適合率と再現率, F値を算出した。

適合率 = AIが対象の品質分類項目のエダマメを対象の品質分類項目へ正しく検出・分類した数 / AIが対象の品質分類項目へ検出・分類したエダマメの数

再現率 = AIが対象の品質分類項目のエダマメを対象の品質分類項目へ正しく検出・分類した数 / テスト画像中の各品質分類項目のエダマメの全個数

表1 各品質分類項目のアノテーション個数

分類項目	全画像データ内のエダマメ総個数(個)			
	AI作成用			精度評価用
	庄内三号	庄内一号	グリーン75	庄内三号
良品	1267	1698	1448	200 (20×10)
一粒	1138	1119	1089	200 (20×10)
欠粒	1180	1353	1160	200 (20×10)
奇形	1375	1357	1224	200 (20×10)
未熟	1235	1477	1145	200 (20×10)
変色	1113	1376	1153	200 (20×10)
莢割れ	1151	1371	1094	200 (20×10)
合計	8459	9751	8313	1400 (140×10)

表2 データセットの構成

データセット名	データセットに含まれる品種
A	庄内三号
B	庄内一号
C	グリーン75
D	庄内三号・庄内一号
E	庄内三号・グリーン75
F	庄内一号・グリーン75
G	庄内三号・庄内一号・グリーン75

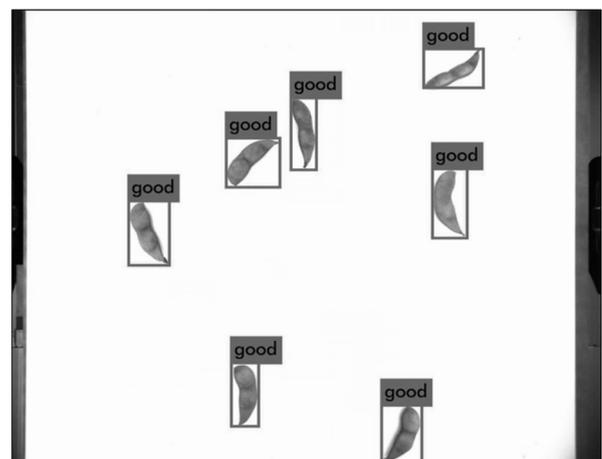


図2 物体検出AIによるエダマメ検出と外観品質分類例

表3 各データセットで作成したAIのF値

データセット 名	分類項目							
	良品	一粒	欠粒	奇形	未熟	変色	莢割れ	平均
A	0.76 a	0.95 a	0.84 ab	0.82 ab	0.74 a	0.90 a	0.83 a	0.83 ab
B	0.64 bc	0.93 a	0.76 b	0.70 a	0.32 c	0.91 a	0.80 a	0.72 c
C	0.57 c	0.85 b	0.61 c	0.71 c	0.25 c	0.92 a	0.81 a	0.67 c
D	0.77 a	0.95 a	0.87 a	0.80 ab	0.60 ab	0.92 a	0.87 a	0.82 ab
E	0.81 a	0.97 a	0.89 a	0.84 a	0.72 a	0.95 a	0.89 a	0.86 a
F	0.72 ab	0.94 a	0.84 ab	0.75 bc	0.42 bc	0.94 a	0.86 a	0.78 b
G	0.79 a	0.97 a	0.90 a	0.85 a	0.70 a	0.94 a	0.86 a	0.86 a

注：AI間において異なるアルファベット間に有意差あり（有意水準5%）

$$F \text{ 値} = 2 \times \text{適合率} \times \text{再現率} / (\text{適合率} + \text{再現率})$$

適合率は、物体検出AIがエダマメを対象の品質分類項目へ検出・分類したものの内、正確に検出・分類した割合を示す指標である。再現率は、物体検出AIがエダマメを正解データの品質分類項目に対し、正確に検出・分類した割合を示す指標である。F値は適合率と再現率の調和平均であり、AIがテスト画像のエダマメをどれだけ誤検出や未検出をせずに正解の品質分類項目へ分類できたかを示す指標である。本研究ではF値を用いて各AIの精度を比較した。F値のデータは10反復収集した。

本実験の統計処理は分散分析をExcel 2013(Microsoft)で行い、多重比較をSAS 9.4(SAS Institute Japan)で行った。多重比較はTukey法で行い、各統計処理の有意水準は5%とした。

3. 結果と考察

各AIのF値の結果を表3に示す。各AI・分類項目のF値の平均はデータセットEとGのAIが0.86と最も高く、データセットCのAIが0.67と最も低かった。AI間でF値の平均に有意差が見られた。

1種類の画像データのみを含むデータセットAとB、CのAIの比較では、F値の平均が選別対象の庄内三号のみを含むデータセットAのAIで有意に高かった。選別対象の品種と異なる品種の画像データで作成した物体検出AIは、外形の特徴が選別対象の品種と異なるため、物体検出AIの精度が低下したと考えられる。次に、複数の品種の画像データを含むデータセットD、E、F、GのAIの比較では、F値の平均は、データセットFのAIが最も低くなった。データセットD、E、Gは選別対象の庄内三号の画像データを含むが、データセットFには庄内三号の画像データが含まれていない。そして、データセットD、E、GのAIの適合率と再現率、F値の平均は、データセットAの物体検出AIと同等となった。これは、データセットに選別対象の品種のデータ比率が低い場合でも、物体検出AIの精度が選別対象品種のデータのみで作成した場合と同程度になることを示す。

以上より、高精度なエダマメの外観精選別用AIを作成するには選別対象品種の画像データをデータセットに必ず含む必要がある。また、選別対象品種の画像データを十分に収集できなかった場合には、他の品種の画像データを混合したデータセットを用いても物体検出AIの精度に影響を及ぼさないといえる。これは、特定の品種で大量のデータを収集できない場合でも他品種の画像データを混合することで分類精度を向上させることができ、様々な品種の外観精選別に適用可能な高精度AIを作成できるといえる。

しかし、森らの先行研究において、選別対象であった「庄内三号」と選別対象ではなかった「秘伝」の2品種のエダマメ画像データを混合して作成した物体検出AIは、「庄内三号」の画像データのみで作成したAIよりも外観品質分類精度が低くなった。本研究では庄内三号とそれ以外の品種の画像データを混合したデータセットD、E、Gで作成したAIは、庄内三号のみ含むデータセットAで作成したAIとF値が同等となった。よって、データセットに含めることでAIの精度が低下する品種の組合せが存在するといえる。今後、データセットに混合することでAIの精度が低下しない品種の決定要素を検討する必要がある。

4. 物体検出AIを用いたエダマメ精選別機の開発

本研究で使用したAI作成用のフレームワーク「Darknet」は、短いコマンドをPCへ入力するだけで物体検出AIの作成と動作を容易に行える。さらに、Darknetはカメラで撮影した動画をリアルタイムで物体検出AIへ入力し、フレーム単位で物体検出AIが検出・分類した内容をJSON形式でリアルタイム出力する機能がある。従って、DarknetとDarknetが出力したエダマメの座標情報を基に不良品除去部分へ信号を送るプログラムを組み合わせれば、物体検出AIを搭載した高精度なエダマメ外観精選別機を開発できる。そこで、著者らはDarknetを中核とした試作エダマメ外観精選別機を製作した。

試作機の概略図を図3に示す。試作機は、ベルトコンベヤによるエダマメ搬送部と検出部、Darknetと物体検出AIなどを含む情報処理部、そして不良品除去部で構成される。

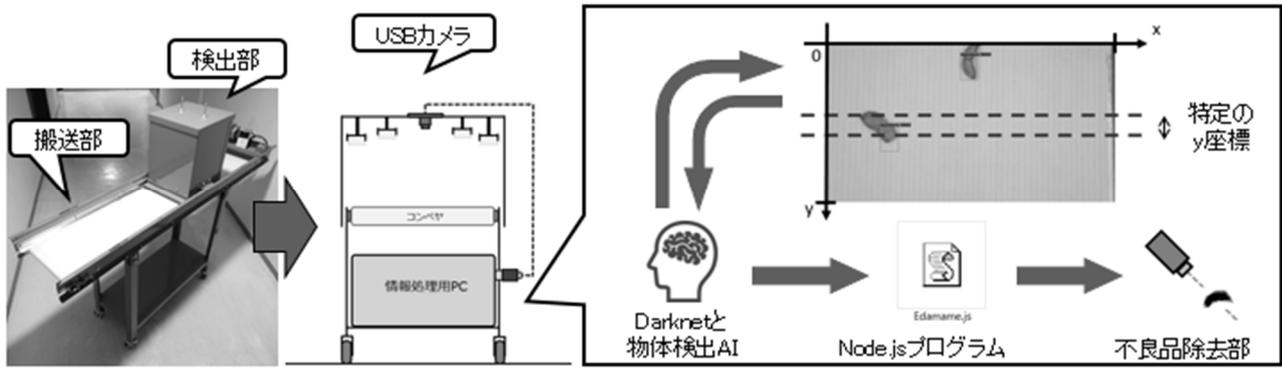


図3 物体検出AIを搭載したエダマメ外観精選別試作機の概略図

最初に、検出部のUSBカメラが搬送部を流れるエダマメを撮影し、その映像はDarknetを介して物体検出AIへ入力される。次に、物体検出AIはUSBカメラの動画をフレーム単位で処理し、フレーム毎のエダマメの座標と外観品質分類結果を出力する。その出力情報をDarknetがJSON形式のログデータとして出力する。

そして、そのJSONデータをDarknetから受け取り、その中から特定のy座標の範囲内にあったエダマメの情報のみを抜き出すNode.jsプログラムが、Darknetと連動して稼働する。物体検出AIは動画をフレーム単位で取り込んで物体検出するが、前フレームの物体検出結果の情報を保持していないため、搬送部を流れていく同一のエダマメを追跡することができない。そのため、本試作機では特定の座標に到達したエダマメの情報のみを使用してエダマメの座標と外観品質の情報を得る仕組みとした。この特定のy座標内に不良品へ分類されたエダマメがあった場合、そのエダマメのx座標情報を基に、そのx座標をカバーしている不良品除去部へ信号を送る。エダマメの外観精選別は、この一連の流れで行うことが可能である。

本試作機は不良品除去部が未完のため、特定のy座標内で検出されたエダマメの外観品質分類項目とその個数をカウントするプログラムを作成し、Darknetと物体検出AI、そしてNode.jsプログラムの連動によるエダマメ個数カウント試験を行った。その結果、物体検出AIによるエダマメの未検出や2重カウントなどが発生したが、特定のy座標内のエダマメの外観品質分類項目とその数をカウントすることができた。以上から、簡素で高精度なエダマメ外観精選別機を開発するには、Darknetと物体検出AI、そしてDarknetが出力するJSONデータを受け取って特定のy座標内の情報のみ抽出するプログラムを連携させることで実現可能である。

現在、Darknetは「YOLO LICENSE Version2」というオープンソースライセンスでリリースされており、無料で誰でも利用可能であるため、Darknetを用いて自分の用途に合った物体検出AIを容易に作成できる。すなわち、生産者は本研究の考察を基にエダマメの画像データを収集し、それを物体検出AIに分類させたい項目を設定してアノテーションを行えば、自分の目的に合った物体検出AIを作成できる。従来、このような画像処理ソフトウェア(AI)は高度なプログラムの知識を有する専門家のみ作成可能であったが、今では画像データを収集してアノテーションを行えば、

Darknetが自動で物体検出AIを作成する。生産者がエダマメの外観精選用のAIを自作するようになれば、選別機メーカーがAI開発費を抑えることができ、従来よりも安価な選別機を市販化できるようになる。AIを搭載した選別機の普及は、エダマメ外観精選別作業の高効率化と現場に適合した生産物の出荷が可能となり、生産者の収益向上に寄与できる。

5. 摘要

- (1) 本研究では、データセットに含むエダマメの品種の違いがエダマメ外観精選用の物体検出AIの検出・分類精度に与える影響を調査した。
- (2) 単一品種のデータで構成されたデータセットで作成したAIの比較では、F値の平均は、選別対象品種の画像データをデータセットに加えた場合に他品種の画像データのみで作成された物体検出AIよりも有意に高くなった。
- (3) 選別対象品種とそれ以外の品種を混合したデータセットで作成した物体検出AIは、F値の平均が選別対象の品種の画像データのみで作成した物体検出AIと同程度であった。
- (4) 高精度なエダマメの外観精選用の物体検出AIを作成するには、選別対象の品種の画像データをデータセットに必ず含む必要がある。

参考文献

- 1) 片平光彦, 張樹槐, 大泉隆弘, 後藤恒義, 鶴沼秀樹, 田村晃, 後藤克典, 2011. 画像処理によるエダマメの選別方法に関する研究(第2報) 試作エダマメ選別機の性能評価, 農業機械学会誌, 73(2), 127-134.
- 2) 森智洋, 片平光彦, 2019. ディープラーニングを用いたエダマメ品質判定用AIの作成とその精度評価, 農業食料工学会東北支部報, 66, 9-12.
- 3) Redmon, J., Farhadi, A., 2018. YOLOv3: An Incremental Improvement. <https://arxiv.org/pdf/1804.02767v1.pdf>. Accessed May. 9, 2020.

マメ科混播草地における草種識別法の検討（第二報）

大出亜矢子*・田中勝千*

Detection of Species Composition in Mixed Legume-grass Pasture Field -Second Report-

Ayako Oide*・Katsuyuki Tanaka*

Abstract

Image classification methods are broadly divided into pixel-based classification that use spectral information and object-based classification that use object information such as shapes and textures. In recent years, AI (artificial intelligence) methods such as machine learning or deep learning have been combined with these existing methods and applied to issues in various fields. In the field of pasture production, control of weeds such as broad-leaved dock (*Rumex obtusifolius*), which has a high seed diffusion ability and hinders the growth of grasses, is an issue for pasture management. Therefore, the attention has been focused on the methods of identifying grass species by using UAVs and application of machine learning or deep learning of aerial images. In the first report, the authors verified the accuracy of grass species identification by processing aerial images with a neural network, and set the task of distinguishing between bitter dock and legumes. This second report reports the results of examination of effective features for each of pixel-based image classification and object-based image classification in order to improve misclassification between these grass species.

[Keywords] machine-learning, UAV, weed control, ratio of legume pasture

1. 緒言

画像分類手法は、スペクトル情報を解析に用いるピクセルベースの分類法と、形状やテクスチャ等のオブジェクト情報を解析に用いるオブジェクトベースの分類法の2つに大別される。近年では、こうした既往の手法に機械学習やディープラーニング等のAI（人工知能）手法を組み合わせた画像処理が、多分野の課題に応用されている。

牧草生産の現場においては、高い種子拡散能力を有し、イネ科牧草の生長を妨害する強害雑草であるエゾノギンギシ (*Rumex obtusifolius*) の駆除が採草地管理の課題とされている。採草地の草種を把握する手法として上空から広範囲を補足可能な無人航空機 (Unmanned Aerial Vehicle: UAV) の活用が進んでいる。UAVの活用により植生情報を一度に把握することが可能となる。得られた採草地の空撮画像から草種を識別する上で、コンピュータにデータを学習させ、未知のデータを分類する機械学習が注目される。空撮画像から圃場全体の雑草の被覆状況を精緻にとらえることを可能とする画像解析法の開発は草地管理に資する重要な課題である。

一般に機械学習による画像解析の精度は学習データに依存するが、マメ科混播草地において空撮画像の画素は複数草種が混合して記録されるため、下層に匍匐的に生長するマメ科の精緻な分類のためには、学習データとして各草種のピュアピクセルの画素値を与えることが望ましい。そこで第一報では、機械学習の手法の一つであるニューラルネットワーク

を空撮画像に適用し、学習データサイズと学習回数が精度に与える影響や識別精度を検証した。この結果、200個体分の学習データを使用した場合に、82.80%と比較的高い識別の全体精度 (Overall Accuracy) が得られたが、草種別の平均精度はばらつきが大きく、特にマメ科牧草をエゾノギンギシとする誤分類が多く検出され、実用に向けてはマメ科牧草とエゾノギンギシ牧草の判別精度の改善が課題として示された (大出ら, 2019)。

強害雑草であるエゾノギンギシは、生長に応じて葉の色や形状が大きく変化する。このことから、空撮を実施した時期や採草地を構成する草種環境により他草種への誤分類が生じることが考えられた。そのため、採草地の空撮画像から多様な生長段階にあるエゾノギンギシを識別するためには、状況に応じた特徴量の活用が精度向上に有効と考えられる。

そこで本研究 (第2報) では、オブジェクトベースの画像分類において学習に使用される形状や、ピクセルベースの画像分類において使用される分光スペクトル等のエゾノギンギシの生長に応じて変化する特性値の時系列変化およびそれらの草種間の比較を行い、草地環境別に識別に有効な特徴量の検討を行った。

2. 材料と方法

(1) 使用データ

1) 供試圃場

調査は北里大学獣医学部附属フィールドサイエンスセン

ター十和田農場第二圃場内の採草地を対象とした。採草地はオーチャードグラス (*Danctylis glomerata* L.) が優占する混播草地である。その他の草種は、イネ科牧草のイタリアンライグラス (*Lolium multiflorum* Lam.)、マメ科牧草のアカローバ (*Trifolium pretense* L.)、シロクローバ (*Trifolium repens* L.) による。牧草以外の雑草種はタデ科のエゾノギシギシ (*Rumex obtusifolius*)、オオバコ科のヘラオオバコ (*Plantago lanceolata*) が確認された。

採草地内の構成草種の異なる3地点(イネ科牧草が優占する地点、マメ科牧草が優占する地点、エゾノギシギシが優占して繁茂する地点)をスペクトルの定期観測地点と定めた。また、採草地内に東西、南北方向にそれぞれ50mの試験区を設定した。試験区は2m四方の小区画に分割し、合計625区画(25×25)設けた(図1参照)。

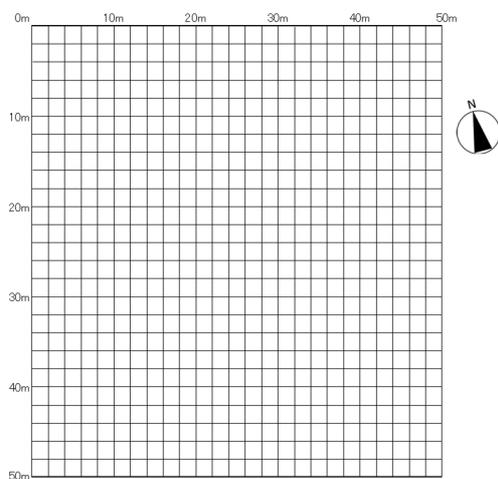


図1 調査試験区

2) 定期観測によるエゾノギシギシの生長観察

周辺の優占環境別をイネ科優占、マメ科優占、裸地優占、その他の4パターンに分類し、それぞれの分類から無作為に個体を抽出し、2019年7月22日から10月17日の期間における生長の特性値(RGB画像、ハイパースペクトル、直径及び草高)の時系列変化を記録した。ハイパースペクトルの測定には、携帯型のハイパースペクトル計(Handheld 2, ASD社)を使用し、325nm~1075nmの波長レンジを連続的に記録した。1個体あたり3つの葉を測定対象とし、一つの葉につき大きな葉脈を避けて3か所を測定した。また、1か所あたり3回連続測定を行いすべての測定値を平均化しその個体のスペクトルとした。

3) 空撮によるスペクトル抽出

2020年10月2日に産業用UAV(Matrice 600, DJI社)により対地高度20mから試験区全体を撮影した。空撮は、400~1000nmの波長レンジから270バンドを連続的に記録可能なプッシュ・ブルーミング分光工法式のNano Hyperpsec(MicaSense社)をUAVに搭載して行った。撮影された270バンドの画像をソフトウェア(Spectral View, Headwall社)により合成しオルソ画像を生成した。植生調査結果と照合し各草種に該当するピクセルのバンド値を分光スペクトルとし

て記録した。草種間のスペクトルの違いを抽出するため生長と周辺環境に応じた各草種のバンド値の差分を算出した。

4) 植生調査

調査区内におけるエゾノギシギシの分布調査は2020年10月8日に実施し、合計625区の全区画におけるエゾノギシギシの位置、被覆面積及び直径を群落調査表に記録した。なお、各区画の優占草種を記録するため、イネ科牧草およびマメ科牧草の被覆面積についても同様に記録した。エゾノギシギシの葉の広がり直径(R)は小(S)サイズ($R < 0.2\text{m}$)・中(M)サイズ($0.2\text{m} \leq R < 0.4\text{m}$)・大(L)サイズ($R \geq 0.4\text{m}$)に分類して記録した。

(2) エゾノギシギシの形状変化の抽出

定期観測したエゾノギシギシの葉の広がり直径および草高の関係を栄養生長期と生殖生長期それぞれについて、草種環境別に整理し、オブジェクトベースの類における有効な特徴量を検討した。

(3) スペクトル変化の抽出

1) 時系列変化の抽出

携帯型ハイパースペクトル計により定期観測されたエゾノギシギシの生長ステージ毎の分光スペクトルの変化を抽出した。

2) 草種間の差分スペクトルの抽出

携帯型ハイパースペクトル計により測定された栄養生長期、生殖生長期のエゾノギシギシのスペクトルとイネ科牧草、マメ科牧草のスペクトルとの間の差分をとり、ピクセルベース分類において有効な特徴量を検討した。

3) 周辺の草種環境別の差分スペクトルの抽出

植生調査の結果より試験区内のイネ科牧草・マメ科牧草およびエゾノギシギシの被度を小区画ごとに集計し、625区画をイネ科牧草の優占区、マメ科牧草の優占区に仕分けをした。その後、UAVに搭載したハイパースペクトルカメラにより測定されたイネ科優占区、マメ科優占区における各草種のスペクトルについて、エゾノギシギシのサイズ、生長段階毎に100ピクセルずつ抽出し平均化した。その後、エゾノギシギシと各草種間の各270バンドの差分を算出し、差分スペクトルを抽出した。これによりピクセルベース分類において採草地環境ごとに草種の識別有効な特徴量を検討した。

3. 結果および考察

(1) 植生指標による草種識別能力の検討

図2は、エゾノギシギシの分布調査の結果を示す。エゾノギシギシの個体数は、Lサイズが752個体、Mサイズが322個体、Sサイズが125個体と、合計1199個体が記録され、西側の試験区に凝集的に分布傾向が見られた。

(2) エゾノギシギシの生長に応じた形状変化

周辺の草種の優占環境別にエゾノギシギシの葉の広がり直径と高さの関係を生長段階別に整理した結果を図3、図4に示す。図3はイネ科優占環境、図4はマメ科優占環境の結果を示す。

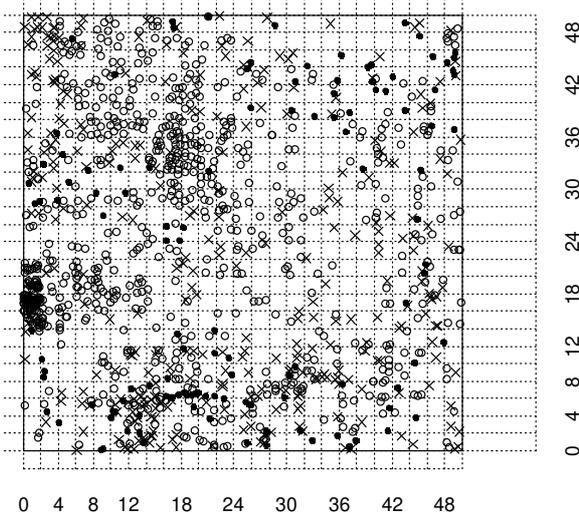


図 2 分布調査結果 (○...L, ×...M, ●...S)

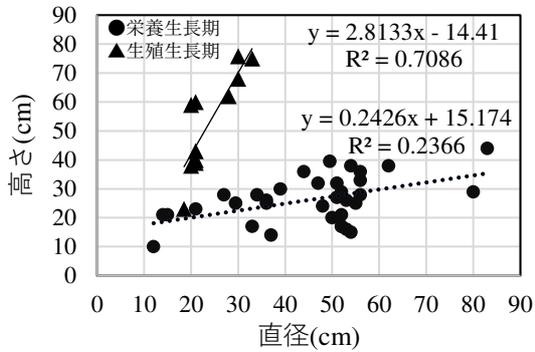


図 3 エゾノギシギシの葉の広がり直径と高さの関係 (イネ科優占環境)

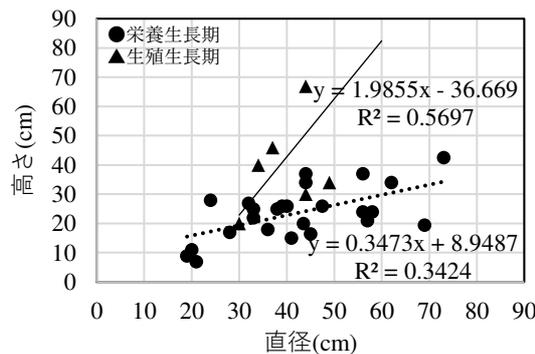


図 4 エゾノギシギシの葉の広がり直径と高さの関係 (マメ科優占環境)

いずれの草種環境においても、栄養生長期では葉が地面と水平方向に展開し、生殖生長期になると垂直方向に草高が急激に伸長する傾向が示された。

イネ科牧草に比べ、マメ科は匍匐的に伸長するため、マメ科優占環境の生殖生長期のエゾノギシギシでは特に、高さ情報を識別に利用することが有効であることが推察された。

(3) エゾノギシギシの生長に応じたスペクトル変化

図 5, 図 6 はそれぞれイネ科優占環境とマメ科優占環境におけるエゾノギシギシのスペクトルの生長に応じた変化を示す。また図 7, 図 8 は栄養生長期と生殖生長期のエゾノギシギシとイネ科牧草およびマメ科牧草とのスペクトル差分を示す。これらを比較すると生殖生長期の近赤外域の差分はイネ科牧草・マメ科牧草ともに近赤外域 (720~920nm) の差分で大きく正の値をとった。刈取り後早期の段階においては栄養生長期の近赤外域 (720~920nm) の差分はイネ科牧草では正の値をとり、マメ科牧草では負の値となった。

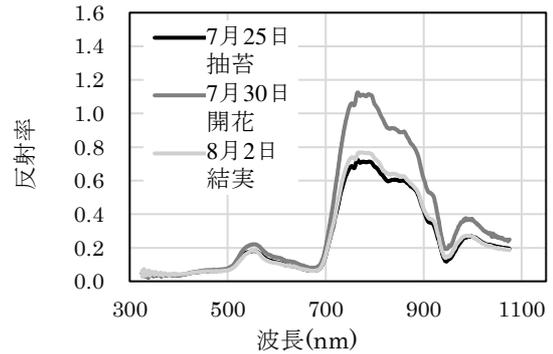


図 5 エゾノギシギシのスペクトル (イネ科優占環境)

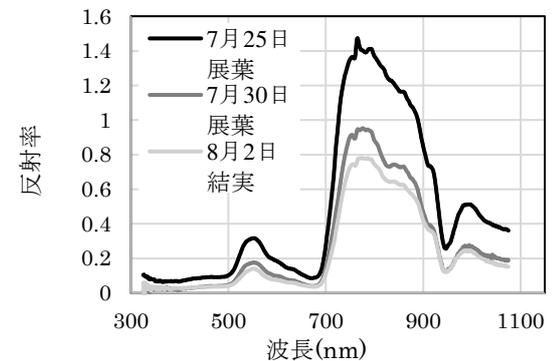


図 6 エゾノギシギシのスペクトル (マメ科優占環境)

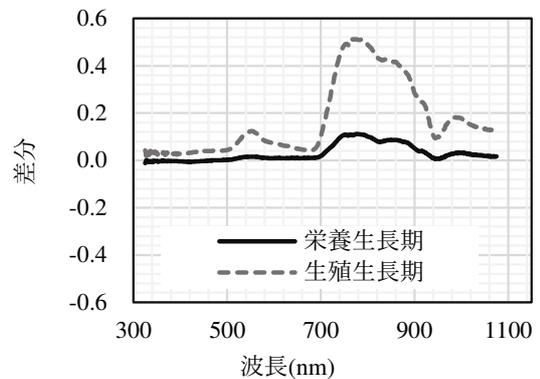


図 7 イネ科牧草とエゾノギシギシの差分スペクトル

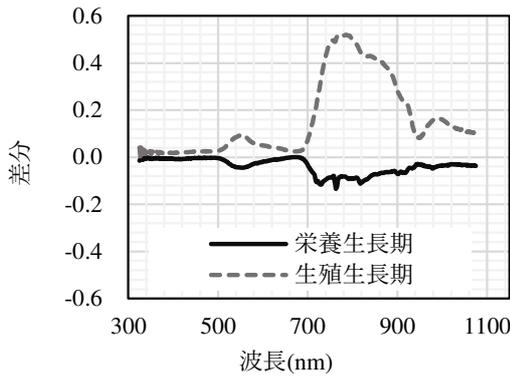


図 8 マメ科牧草とエゾノギシギシの差分スペクトル

さらに表 1, 表 2 は UAV に搭載したハイパースペクトルカメラにより取得された各草種の反射強度間での差分スペクトルを示す(表 1...イネ科優占環境, 表 2...マメ科優占環境)。各分類の近赤外域 (720~ 920nm) の差分の正負に着目する

と、イネ科優占環境におけるイネ科とエゾノギシギシの差分スペクトルは、すべての分類で負の値を示した。また、マメ科優占環境におけるイネ科の差分スペクトルは、すべての分類で正の値を示した。各分類の差分スペクトルは大小の異なる特徴的な値を示した。また、特徴が他分類と重複したものもいくつか見られたものの、多くの分類において他分類からは見られない独特な特性が発見された。

4. まとめ

エゾノギシギシとイネ科牧草およびマメ科牧草のスペクトルの差分の結果、生殖生長期の近赤外域 (720~920nm) の違いからエゾノギシギシの識別の可能性が示された。

参考文献

大出亜矢子・田中勝千・皆川秀夫, 2019, マメ科混播草地における草種識別法の検討 (第二報), 農業食料工学会東北支部報 No.66 : 29-32

表 1 イネ科優占環境におけるエゾノギシギシと周辺草種との差分スペクトル

(RO...エゾノギシギシ, PO...イネ科, FA...マメ科, Intensity=反射強度, Wavelength=波長)

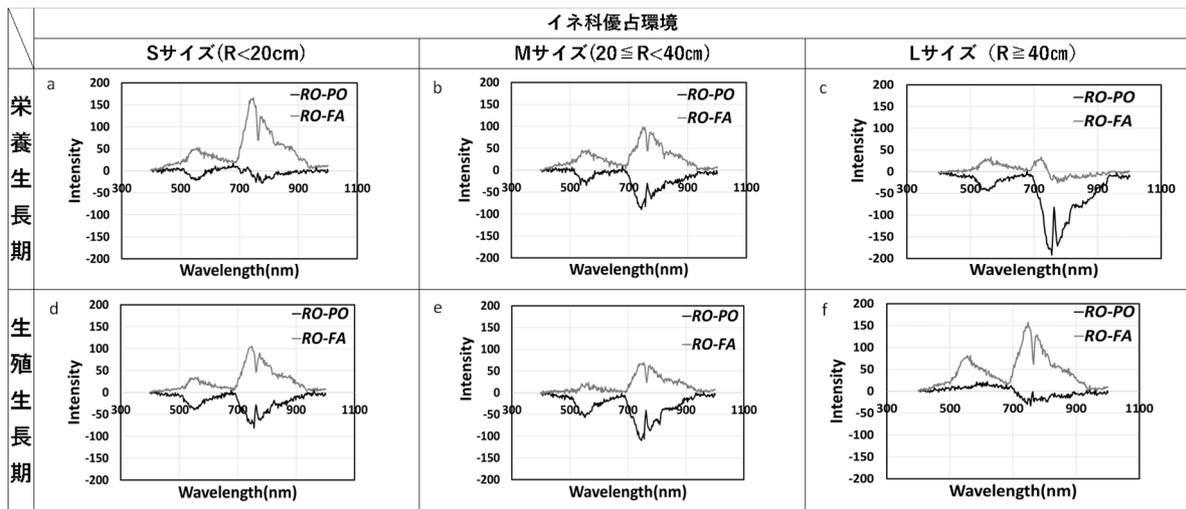
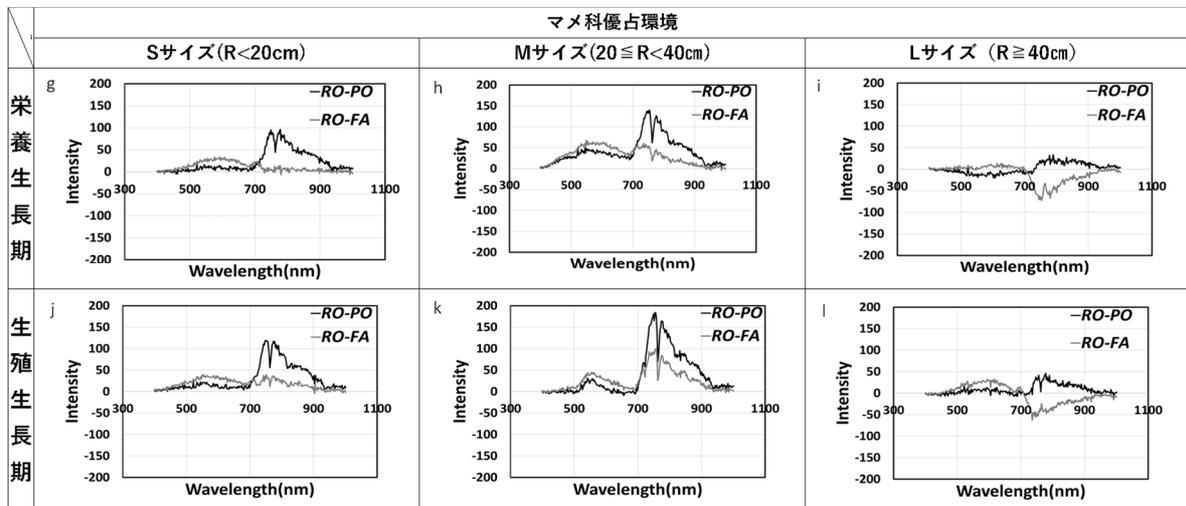


表 2 イネ科優占環境におけるエゾノギシギシと周辺草種との差分スペクトル

(RO...エゾノギシギシ, PO...イネ科, FA...マメ科, Intensity=反射強度, Wavelength=波長)



TOHOKU BRANCH REPORT
OF
THE JAPANESE SOCIETY OF AGRICULTURAL MACHINERY AND FOOD ENGINEERS

CONTENTS

Essay : ZHANG Shu-huai

RESEARCH PAPERS

Genta KANAI • Namiko YOSHINO

Application of Automatic Lawn Mower to Agriculture 1

Dhirendranath SINGH • Shigeru ICHIURA • Thanh Tung NGUYEN • Mitsuhiko KATAHIRA

Rice Tiller Detection using Deep Learning and Field Robot 5

Mitsuhiko KATAHIRA

Investigated on Agricultural Machinery and Post-Harvest Technology in Ethiopia 9

Shinsuke KONNO • Hideya HIRUMA • Ken-ichi HORIGUCHI • Mitsuhiko KATAHIRA

Gaze Characteristics of Livestock Farmer during Grasping the State of Livestock using Eye-Mark Recorder 13

Tomohiro MORI • Mitsuhiko KATAHIRA

Effects on Accuracy of Object Detection AI by Difference in Green Soybean Varieties Included in Dataset 17

Ayako OIDE • Katsuyuki TANAKA

Detection of Species Composition in Mixed Legume-grass Pasture Field —Second Report— 21

NOTES 25

ORGANIZATION DIRECTORY 46