

# トラクタ位置情報履歴を用いた農作業推定技術

全 慶樹, 藤澤 怜央, 近藤 正一, 堀 武司

## Estimation of Agricultural Work Type using Tractor Location Histories

Keiki ZEN, Reo FUJISAWA, Shouichi KONDOU, Takeshi HORI

### 抄 録

農作業の記録は農作業計画の改善やノウハウの継承に役立つが、農作業の情報を手作業で詳細に記録することは大きな負担となっており、記録作業の省力化や自動化が必要とされている。本研究では、畑作を対象に農作業情報の記録作業の自動化について取り組んだ。トラクタの位置情報データ及び圃場データを機械学習により分析することで、農作業情報として重要な作業機の種類を推定する技術を開発した。あわせて、トラクタの位置情報データを安定的に取得し、記録された農作業情報をウェブ上で確認できるシステムを試作した。

キーワード：機械学習, 位置情報履歴, 農作業

### Abstract

Agricultural work records are useful for improving farm planning and knowledge transfer. However, it is a heavy burden to manually record detailed agricultural work information, and labor-saving or automation of the recording process is required. In this study, we investigated the automation of the recording of agricultural work information for upland farming. We developed a technique to estimate the type of work machine connected to a tractor, which is important as the agricultural work information, by analyzing the tractor location data and the field data using machine learning. We also prototyped a system that can stably acquire the tractor location data and check the recorded agricultural work information on the web.

KEY-WORDS : Machine learning, Location history, Agricultural work

## 1. はじめに

農作業記録は、農作業計画の改善やノウハウの継承に有用である。農作業を行った時間や場所、作業内容等の履歴情報は、農作業日誌や営農管理システム(Farm Management Information System, FMIS)に作業者の手によって記録されることが一般的である。しかし、日々の作業のなかで農作業の情報を詳細に記録することは大きな負担となっており、人の手による記録は抜け漏れの発生にもつながるため、記録作業の省力化や自動化が必要とされている。

本研究では、畑作を対象に農作業情報の記録作業の自動化について取り組んだ。道内の畑作地帯では農家戸数の減少に伴い、一戸あたりの経営耕地面積が増加しており<sup>1)</sup>、一つの農家が広く分布する多数の圃場を運用する傾向にある。その

ため圃場によって異なる標高や気候、圃場間の移動距離などを考慮した営農が行われており、農家にとって過去の農作業記録は重要なノウハウであるといえる。



図1 農業用トラクタと作業機

事業名：経常研究

課題名：機械学習による大規模時系列データの状態推定に関する研究

畑作では、耕起や播種、施肥、収穫などに応じた作業機をトラクタに取り付けて農作業を行う（図1）。したがって、畑作における農作業の情報は、トラクタの位置情報履歴及び取り付けられていた作業機の種類からおおよそ把握することができる。そこで農作業記録の自動化にあたっては、これらのデータを自動的に取得あるいは推定するアプローチを選択した。トラクタの位置情報履歴に関しては、トラクタに搭載されているGPS機能やスマートフォンなどのIoT機器、市販のデータロガー等を利用して比較的容易に取得できると考えられる。一方で、取り付けられていた作業機の種類に関しては、一部のISOBUS対応機器を除いて作業機の種類を自動的に取得することが難しいため、ほかのデータを利用して推定する必要がある。

本研究では、トラクタ位置情報履歴等のデータを機械学習により分析することで、取り付けられていた作業機の種類を推定する技術を開発した。また、記録作業の自動化に向けて、遠隔地のトラクタから必要な位置情報データを安定的に取得し、記録された農作業情報をウェブ上で確認できるシステムを試作したのであわせて報告する。

## 2. データセットの作成

機械学習による作業機の推定に使用するデータセットは、トラクタの位置情報データ及び圃場データ（圃場図と作付情報）をもとに作成した。本データセットの作成方法について述べる。

### 2.1 トラクタ位置情報データの取得

道内農業法人の協力のもと複数台のトラクタのキャビンに小型のデータロガーを設置し、トラクタ位置情報データを取得した。この農業法人では、数年前からトラクタ位置情報データの取得試験を行っており、十分なデータを取得できた2015年と2016年のデータを分析に使用した。それぞれの年で11台のトラクタからデータを取得しており、データの総数は2年分で約650万となった。

また、今回使用したデータロガーは通信機能を持たず内部




図2 圃場図及びトラクタのGPS位置情報履歴（走行軌跡として表示）

メモリにデータを保存するため、メモリ節約のためにデータの記録間隔を5秒に設定した。

トラクタ位置情報データの例を図2に示す。図ではGPSの位置情報の点をつないだ走行軌跡として表示しており、2つの圃場での圃場内作業と圃場間移動の様子を確認することができる。

### 2.2 圃場図及び作付情報の利用

記録された各点が圃場内作業か圃場間移動かを判別するために地図上で圃場の領域を表した圃場図を利用した。また、農作業推定の手がかりとして各圃場の作付情報を利用した。圃場図は年によって大きく変化しないが、作付情報は年ごとに化する。これは北海道では4品目（小麦、馬鈴薯、甜菜、豆類）の輪作が普及しており<sup>1)</sup>、同一圃場でも前年と異なる作付になる場合が多いためである。

圃場図と作付情報の例を図2に示す。各圃場の領域は緯度経度のポリゴンデータとして保存されている。

### 2.3 単位作業の計算

本研究の農作業推定では、トラクタが圃場に入ってから退出するまでを一回の農作業の単位とし、これを単位作業と呼ぶ。単位作業の例を図3に示す。

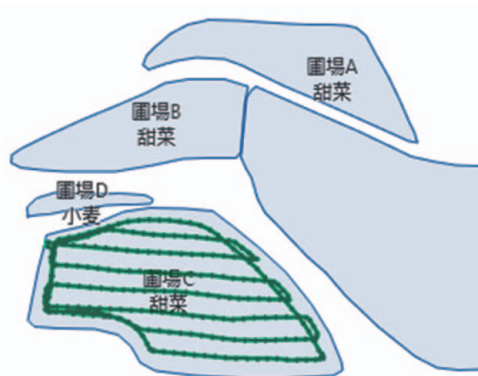


図3 単位作業の例（圃場C内の濃色の点線）

単位作業ごとに農作業推定を行うため、位置情報データの系列を単位作業に分割する必要があるが、圃場図を利用して単純に圃場内にある連続する点をまとめる方法では、一つの単位作業を細かく分割してしまう恐れがある。これは圃場図の精度またはGPS測位精度の低下により、単位作業の一部の点が圃場外に記録されてしまうことによる。このような点は圃場の境界で頻繁に発生する（図4）。そこで、次の手順で単位作業への分割を行った。

- (1) 圃場図を利用して各点が所属する領域（各圃場または圃場外）を判別する。
- (2) 各点の前後90秒間の点について所属する領域を集計し、最も多い領域をその点の作業対象の領域とする。
- (3) 同じ作業対象の領域が連続する点をまとめて一つの単




図4 単位作業の一部が圃場外に記録された例

位作業とする。

これにより多くの場合で適切な単位作業の計算が可能となった。

なお、点がどの領域に含まれるかなどの空間分析には PostgreSQL 上の PostGIS 等を使用した。また、座標系は必要に応じて平面直角座標系に投影して空間分析を行った。

#### 2.4 ラベルの付与

機械学習のうち教師あり学習は、入力データとそれに対応すべき出力（ラベル）が必要になる。今回の農作業推定では、単位作業から計算された入力に対し、その時トラクタに取り付けられていた作業機の情報がラベルとして必要である。2015～2016年に取得した位置情報データについては、作業者が記録した農作業記録にもとづきラベルの付与を行った。

以上の手順により、計9種類の作業機（スプレーヤ、ブロードキャスト、サブソイラ、ビート移植機、ロータリ、プラウ、カラット、カルチベータ、コンビドリル）を含むデータセットを作成した。各作業機のデータ数（単位作業数）を表1に示す。なお、以降で述べる機械学習では2015年のデータセットを学習用及び検証用に使用し、2016年のデータセットをテスト用に使用した。

表1 データセットの単位作業数

作業機（農作業）	2015年	2016年
スプレーヤ（防除）	471	1,026
ブロードキャスト（施肥）	266	191
サブソイラ（心土破碎）	228	165
ビート移植機（移植）	194	119
ロータリ（砕土・整地）	142	171
プラウ（耕起）	127	168
カラット（混和・耕起）	124	118
カルチベータ（中耕・除草）	110	119
コンビドリル（播種等）	87	98
合計	1,749	2,175

※ 平均速度 1 km/h 以下または作業時間 5 分以下の単位作業、データ数の少ない作業機を除く。

### 3. 機械学習による農作業推定

作成したデータセットに機械学習アルゴリズムを適用し、各单位作業の農作業を推定した。アルゴリズムの適用方法と推定結果について述べる。

#### 3.1 勾配ブースティング決定木

機械学習アルゴリズムには、勾配ブースティング決定木（Gradient Boosting Decision Tree, GBDT）の一種である LightGBM<sup>2)</sup>を使用した。近年の勾配ブースティング決定木は、高度なデータ分析の問題に対してディープラーニングと並び広く使用されているアルゴリズムであり、巨大なニューラルネットワークを用いるディープラーニングと比べ高速に計算できるほか、欠損値やカテゴリカル変数をうまく扱える<sup>3-4)</sup>等の性質から汎用性に優れている。今回対象とするデータは位置情報の系列などを含みディープラーニングの適用方法が明らかではないため、汎用性の高い勾配ブースティング決定木の適用を検討した。

ディープラーニングは画像データを得意とする畳み込みニューラルネットワークのようにネットワークの内部で高度な特徴量を抽出する。一方で、勾配ブースティング決定木は多くの機械学習アルゴリズムと同様にあらかじめ問題の特性に合わせた特徴量を計算し、アルゴリズムへ入力する必要がある。以降ではアルゴリズムへの入力について説明する。

#### 3.2 位置情報データの入力

勾配ブースティング決定木への入力は固定長である必要があるため、含まれるポイント数がそれぞれ異なる単位作業の位置情報データをそのまま入力することはできない。そこで次の特徴量を計算し固定長の入力とした。

- 単位作業の総移動距離
- 平均速度
- 速度の標準偏差
- 速度の中央値を含むパーセンタイル

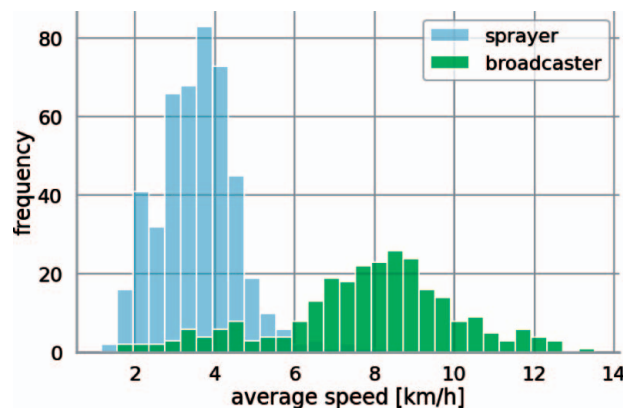


図5 単位作業の平均速度に関するヒストグラム（スプレーヤとブロードキャスト）



- 方位角の変化量の平均
- 方位角の変化量の標準偏差
- 方位角の変化量の中央値を含むパーセンタイル
- 単位作業に含まれるポイント数

単位作業の平均速度に関するヒストグラムの一部を図5に示す。スプレーヤとブロードキャストの識別には平均速度が有効であることが確認できる。

### 3.3 作業面積情報の入力

作業機の種類によって作業幅は様々であり<sup>5)</sup>、同じ速度で走行した場合でも単位時間あたりの作業面積に違いが生じる。この特徴を捉えるために単位作業の作業面積を計算し、作業時間で除算した値を入力の一つとした。

単位作業の作業面積を計算する方法として単純に圃場図から作業を行った圃場の面積を計算する方法が考えられるが、単位作業において圃場の一部分を対象に作業する場合も多いため適さない。次に単位作業に関する凸包を計算する方法について考える。ここでの凸包は、与えられた点集合をすべて包含する最小の凸多角形のことであり、効率的に計算できるアルゴリズムが知られている。単位作業の凸包の例を図6(a)に示す。凸多角形は凹みがないため、図の例のように作業を行った領域が凹んでいる場合は、実際の作業面積との乖離が大きくなることがわかる。そこで、作業面積の計算には凸包を一般化したアルファシェイブ(alpha shape)を使用した。

アルファシェイブは、凹みのある形状を含む凸包の一般化

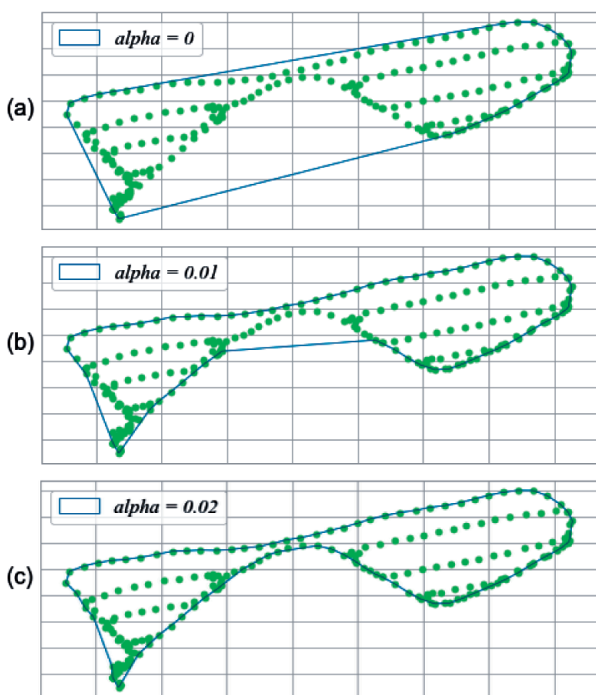


図6 アルファシェイブによる作業面積の計算 (アルファパラメータを0, 0.01, 0.02とした例)

表2 農作業推定結果

作業機 (農作業)	F 値 [%]
スプレーヤ (防除)	95.6
ブロードキャスト (施肥)	94.8
サブソイラ (心土破碎)	92.3
ビート移植機 (移植)	82.9
ロータリ (碎土・整地)	98.5
ブラウ (耕起)	90.6
カラット (混和・耕起)	90.3
カルチベータ (中耕・除草)	86.7
コンビドリル (播種等)	91.6
正解率 [%]	93.4

※ 2015年のデータセットで学習したモデルを使い、2016年のデータを推定した。

であり、アルファパラメータにより形状を調整する。 $\alpha = 0$ のときは凸包であり、 $\alpha$ を徐々に大きくすると点集合を包含したまま領域が小さくなる(図6)。 $\alpha$ の値によっては複数の領域に細かく分割される場合もあるため、データに合わせて $\alpha$ の調整が必要だが、本研究ではデータセットに共通のアルファパラメータを事前に計算し適用した。

これにより計算された単位作業の作業面積をポイント数で除算し、単位時間あたりの作業面積の近似値とした。

### 3.4 そのほかのデータ

そのほか圃場の作付情報、トラクタ機種名、時間に関連する情報として月(month)、時(hour)、年始からの経過日数を入力として与えた。

### 3.5 学習と推定結果

2015年のデータセットを学習に使用した。学習ではデータセットの20%を検証用として分離し、過学習を抑制するための早期停止<sup>6)</sup>(early stopping)とモデルの選択に使用した。

学習したモデルを使い、2016年の農作業を推定した結果を表2に示す。農作業全体の正解率は約93%となった。

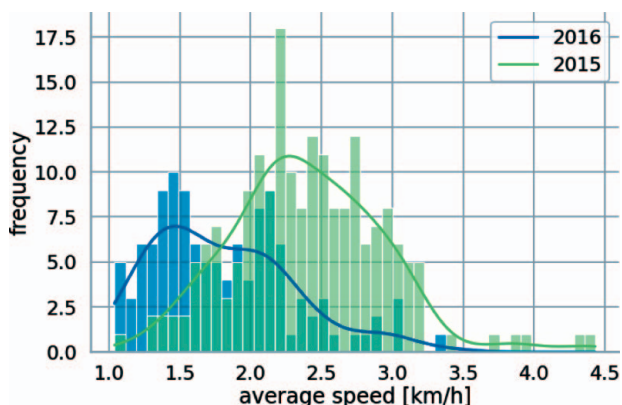


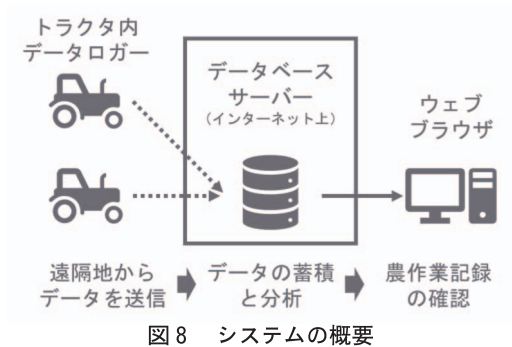
図7 各年のビート移植機の比較 (単位作業の平均速度に関するヒストグラム)

### 3.6 考察

農作業全体に対しての識別性能は高いが、一部の農作業の識別性能は相対的にやや低く、ビート移植機のF値は約83%と今回の農作業のなかでは最も低い。各年のビート移植機の平均速度を図7に示す。2015年と2016年を比較して、ほかの農作業では見られなかったピークのずれなどの分布の変化が確認できる。ビート移植機に関しては、このようなデータの特徴の変化が性能に影響を与えたと考えられる。


## 4. 農作業記録システムの試作

記録作業の自動化に向けて、遠隔地のトラクタから必要な位置情報データを安定的に取得し、記録された農作業情報をウェブ上で確認できるシステムを試作した。システムの概要を図8に示す。



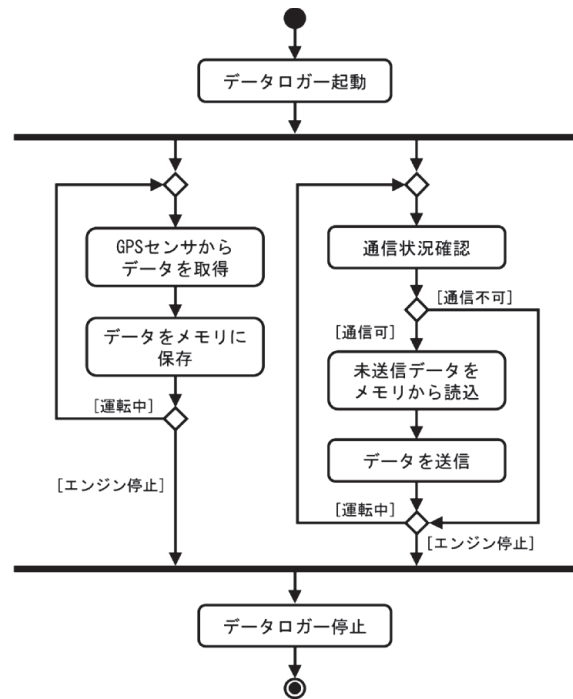


### 4.1 データ取得の自動化

2015～2016年に使用したデータロガーのブロック図を図9に示す。このデータロガーは通信機能を持たず内部メモリにデータを保存するため、定期的なデータの回収作業を必要とした。メモリ節約のためにデータの記録間隔を5秒に設定し、1～2ヶ月に1回の頻度でデータの回収作業を実施した。また、バッテリーで駆動するため、データ回収の際にバッテリーの充電を同時に行った。



今回、このデータの回収作業を自動化するために通信機能付きデータロガーを開発した。開発したデータロガーの外観

を図10に、ブロック図を図11に示す。以前のデータロガーと比べてデータを無線通信で送信する点とトラクタから給電される点が大きく異なっている。トラクタのキャビンに設置されたデータロガーは、携帯電話回線を使用してサーバーへデータを送信する。また、山間部等の圃場は携帯電話回線のエリア外であることが多いため、エリア外で取得したデータは、通信が可能なエリアでまとめて送信する仕組みとした。関連するデータの保存と送信のフローを図12に示す。なお、デー



タの記録間隔を1秒に設定したが、内部メモリは少なくとも1年分のデータを保存できるため、長期間通信できない場合でもデータの欠測を防ぐことができる。以上により全域でのデータの取得を可能とした。

通信プロトコルにはIoTなどで使用されることが多いMQTTを使用した。MQTTは軽量でシンプルなPub/Sub型のプロトコルであり、不安定な通信環境においても通信コストを抑えながら確実にデータの送信を行うことができる。

そのほかの機能としては、筐体の防水、トラクタの稼働に連動した起動、DIN規格のソケットによる給電などがある。

気象条件が厳しい夏季及び冬季にデータロガーの試験を行い、複数のトラクタから安定的にデータを取得できることを確認した。

#### 4.2 農作業記録の確認

サーバーに記録された農作業情報をGUIで確認するためのウェブアプリケーションを開発した。図13に動作画面の例を示す。ウェブブラウザ上で集計方法の切り替えとデータの絞り込みを行うことができる。



図13 ウェブブラウザによる農作業記録の確認

#### 5. おわりに

本研究では、北海道の畑作を対象に農作業情報の記録作業の自動化について取り組んだ。トラクタの位置情報履歴などを機械学習により分析することで、農作業情報として重要な作業機の種類を推定する技術を開発した。道内の農業法人のデータに対して適用した結果、高い正解率で推定できることを確認できた。しかし、学習は1年分のデータで行っているため、今後は複数年のデータや別の農業法人のデータを使用した詳細な性能評価を実施したい。また、遠隔地のトラクタから必要な位置情報データを安定的に取得し、記録された農作業情報をウェブ上で確認できるシステムを試作した。今後は試作したシステムと営農管理システムの連携などの展開を目指す。

#### 参考文献

- 1) 辻 博之：北海道畑作の大規模化における課題と今後の展望，農作業研究，53巻1号，pp. 3-13，(2018)
- 2) Guolin Ke, Qi Meng, Thomas Finley, et al. “Light GBM: A Highly Efficient Gradient Boosting Decision Tree.” Advances in Neural Information Processing Systems 30 (NIPS 2017), pp. 3146-3154.
- 3) Tianqi Chen, Carlos Guestrin. “XGBoost: A Scalable Tree Boosting System.” Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD 2016), pp. 785-794.
- 4) Anna Veronika Dorogush, Vasily Ershov, Andrey Gulin. “CatBoost: gradient boosting with categorical features support.” Workshop on ML Systems at NIPS 2017.
- 5) 北海道農政部：北海道農業生産技術体系 第4版，公益社団法人 北海道農業改良普及協会，521PP，(2013)
- 6) Trevor Hastie, Robert Tibshirani, Jerome Friedman, 他：統計的学習の基礎 データマイニング・推論・予測，共立出版，853PP，(2014)