

## 論 説

# 機械学習を用いた容量型近接センサによる 非接触入力デバイス

柏 尾 知 明\*



## 1. はじめに

近年、COVID-19パンデミックを契機として、人が触れることなく操作可能な非接触インターフェースへの関心が社会的に急速に高まった。公共施設や産業設備において、不特定多数が接触する操作部は感染リスクの観点から課題として認識され、非接触による操作手段の必要性が広く共有されるようになった。このような社会的背景のもと、非接触入力技術は単なる利便性向上のための技術ではなく、安全性や衛生性を確保するための基盤技術として位置付けられるようになった。一方で、現場での実装を考えた場合、システム構成が複雑であったり、設置条件に制約を受ける方式は、必ずしも実用的とは言えない場合がある。

非接触入力技術としては、カメラを用いた画像処理方式や光学式センサなどが存在しているが、これらの方式は照明条件や視野制約、システム構成の複雑さ、高コストといった課題を有する場合がある。これに対し、容量型近接センサは、回路構成が比較的簡素で低コストであり、小型・低消費電力で実装できる点に特徴がある。容量型近接センサは、電極近傍に物体が接近することによって生じる微小な容量変化を検出する方式であり、人体のような導電体に対して高い感度を示す<sup>1), 2), 3)</sup>。この特性を活かすことで、センサ表面に直接接触することなく、手の接近や移動を検出することが可能である。

一方で、容量型近接センサの出力は、対象物の位置や移動方向、速度、さらには個人差や環境条件の影響を受けやすく、センサ出力と動作内容の関係を解析的にモデル化することは容易ではない。特に、複数電極から得られる時系列信号を用いて動作を識別する場合、単純な閾値判定やルールベースの手法では十分な識別性能を得ることが難しい。

そこで本稿では、3電極構成の3次元容量型近接

センサを用いて、その構造および出力特性を整理するとともに、複数電極から得られる時系列信号を用いた動作識別の考え方について解説する<sup>4), 5), 6), 7), 8), 9)</sup>。機械学習を用いることで、テンプレートマッチングでは対応が困難であった複雑な動作パターンに対しても、柔軟な識別が可能となる点を示す。なお、本センサユニットは出口幹雄名誉教授（新居浜高専）が設計し、共同研究として開発しているものである。

## 2. センサの構造と出力

### 2.1 センサユニットの構造

本稿で扱う容量型近接センサユニットは、3つの検出電極を円周上に配置した円形構造を有している（図1）。センサ基板の中心から放射状に配置された3電極は、正三角形を成すように配置されており、各電極が独立した検出チャンネルとして動作する。

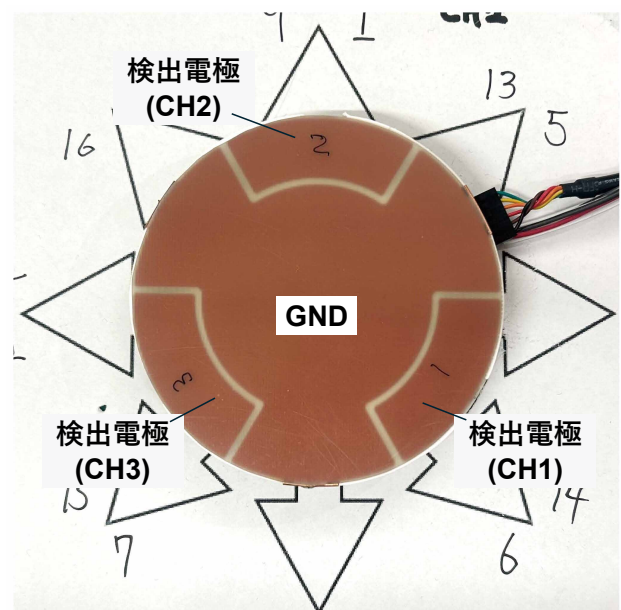


図1 センサユニット

\*近畿大学 理工学部電気電子通信工学科 准教授

各検出電極は、周囲の空間に形成される電界の変

化を通じて、近傍物体の接近を検出する。人体の手がセンサ上方に近づくと、電極と手との間に形成される浮遊容量が変化し、その結果として各チャンネルの検出信号に変化が生じる。3つの電極を用いることで、単一電極では得られない方向性を持った情報を取得できる点が特徴である。

また、センサユニットは比較的少数の汎用電子部品によって構成されており、小型化やシステムへの組み込みが容易である。このような構造は、産業用途において重要となる実装性や拡張性の観点からも有利である。

## 2.2 センサ出力

本センサユニットは、約10cm以内を通過する手や物体を検出するように調整している（図2）。



図2 センサユニット

図3は、全16パターン（図4）の手の動き（約2秒間）に対する、センサユニットの3つの検出電極に対応した3チャンネルの出力信号の平均値を0-1で正規化したグラフである。各チャンネルの出力は、手の接近・移動に伴う容量変化を反映したものであり、動作方向や移動速度に応じて異なる波形形状を示す。例えば、手が特定の電極方向から接近した場合、その電極に対応するチャンネルの出力が先行して変化し、他のチャンネルは遅れて応答する。この応答タイミングや振幅の差が、動作方向を推定するための重要な手掛かりとなる。また、移動速度の違いは、出力波形の時間的な変化量として現れる。

一方で、これらの出力波形は必ずしも単純な形状を示すわけではなく、手の大きさや姿勢、移動のばらつき、さらには周囲環境の影響によって変動する。そのため、出力波形をあらかじめ人が定義したルールによって分類することは難しく、時系列データ全体の特徴を考慮した処理が求められる。本研究では、出力波形の動作パターンへの分類に機械学習を用いた。複数チャンネルの時系列信号を入力とし、データから特徴を自動的に学習できる機械学習手法を用いることで、動作識別の性能とともに、柔軟性および

拡張性を高めることができる。

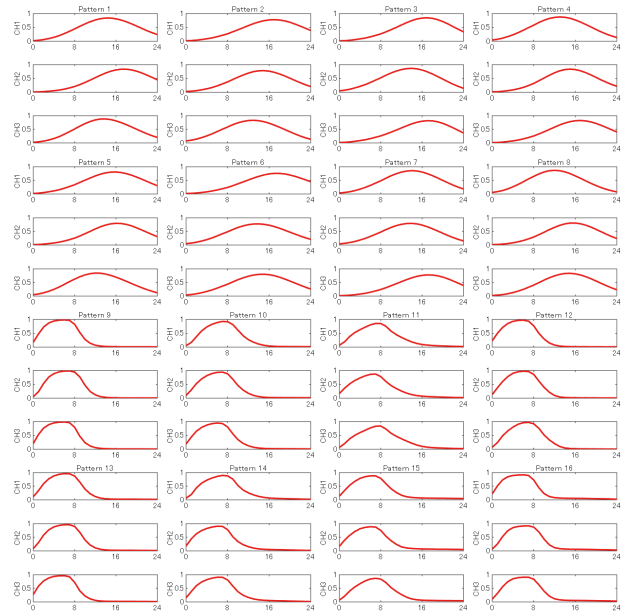


図3 センサ出力

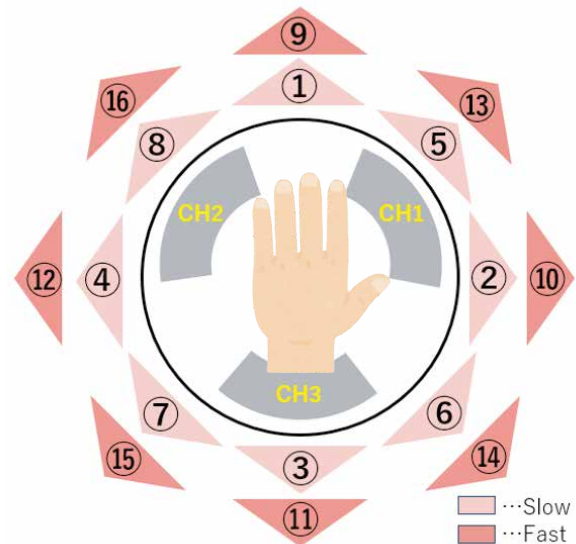


図4 センサユニット上での手の動きのパターン

## 3. 機械学習

### 3.1 分類モデル

前章で述べたように、本センサユニットから得られる出力は、3チャンネルの時系列信号として観測される。これらの信号には、手の移動方向や速度に関する情報が含まれている一方で、個人差や動作のばらつき、環境条件の影響も重畳しており、センサ出力と動作内容の関係は非線形かつ複雑である。

このような特徴を持つデータに対して、あらかじめルールを定めた判定や単純なテンプレートマッチングを適用すると、識別性能が動作条件に大きく依存してしまう。特に、動作パターンが増加した場合や、

類似した動作を区別する必要がある場合には、設計者がルールを逐一調整することは現実的ではない。

そこで本研究では、機械学習を用いてセンサ出力と動作クラスの間をデータ駆動的に学習する方法を採用した。機械学習モデルを用いることで、複数チャンネルの時系列信号に内在する特徴を自動的に抽出し、動作の違いを識別することが可能となる。

本稿では、次の4種類の代表的な機械学習モデルを用いて分類手法を行った。

- ①Linear Regression (LR)
- ②k近傍法 (kNN)
- ③Support Vector Classifier (SVC)
- ④Random Forest (RF)

いずれの手法においても、3チャンネルの時系列信号を特徴量として入力し、動作パターンをクラスとして出力する構成とした。モデルの詳細な構造やパラメータについては割愛するが、比較的少ないセンサ数でも高い識別性能が得られる点が、本方式の特徴である。機械学習を用いる利点は、識別精度の向上だけでなく、動作パターンの追加や変更柔軟に対応できる点にある。新たな動作を定義した場合でも、学習データを追加することでシステムを拡張できるため、用途に応じたカスタマイズが容易である。

### 3.2 分類の評価

本研究では、提案手法の分類性能を定量的に評価するため、混同行列 (confusion matrix) を用いて評価を行った。混同行列は、実際のクラス (パターン) と推定されたクラスの対応関係を集計したものであり、各クラスに対する分類の正否を視覚的に把握することができる。混同行列は、以下の4つの要素から構成される。True Positive (TP) は、対象クラスに属するデータを正しく当該クラスとして識別できたサンプル数を示す。一方、False Positive (FP) は、他クラスに属するデータを誤って対象クラスと判定したサンプル数である。また、False Negative (FN) は、対象クラスに属するデータを他クラスとして誤分類したサンプル数を示し、True Negative (TN) は、他クラスに属するデータを正しく他クラスとして判定できたサンプル数を表す。これらの値に基づき、以下の評価指標を算出した。

Accuracy (正解率) は、次式で表される。

$$\text{Accuracy} = (\text{TP} + \text{TN}) / (\text{TP} + \text{TN} + \text{FP} + \text{FN})$$

全サンプル数に対して正しく分類された割合を示し、システム全体の分類性能を表す指標である。ただし、クラス数が多い場合やクラス分布に偏りがある場合には、Accuracy のみでは性能を十分に評価

できない場合がある。

Precision (適合率) は、次式で表される。

$$\text{Precision} = \text{TP} / (\text{TP} + \text{FP})$$

あるクラスと判定されたサンプルのうち、実際にそのクラスに属していた割合を示す指標であり、誤検出 (FP) の抑制性能を評価するのに有効である。

Recall (再現率) は、実際にそのクラスに属するサンプルのうち、正しく検出できた割合を示し、見逃し (FN) の少なさを評価する指標である。

$$\text{Recall} = \text{TP} / (\text{TP} + \text{FN})$$

F1\_score は、次式で表される。

$$\text{F1\_score} = (2 \cdot \text{Recall} \cdot \text{Precision}) / (\text{Recall} + \text{Precision})$$

Precision と Recall の調和平均であり、誤検出と見逃しの両方を考慮したバランスの取れた評価指標である。本研究のように、多数のジェスチャパターンを扱う多クラス分類問題では、単一の指標だけでなく、混同行列と複数の評価指標を併用することで、分類器の特性や誤分類傾向をより詳細に把握することが可能となる。実際に、類似した動作方向や速度の異なるジェスチャ間では誤分類が生じやすく、これらは混同行列上で隣接クラスへの誤判定として確認された。この結果は、単純なテンプレート照合手法では捉えきれない非線形性や時間的歪みが存在することを示唆している。

## 4. 実験結果

センサユニットの出力と動作パターンを組み合わせた15,308 (学生4名分) のデータセットを学習用10,715、テスト用4,593に分割し、各機械学習モデルに学習させた。各学習済み分類モデルの有効性を確認するため、学習用データの作成に関わっていない学生8名 (各学生10回/パターン) のパターンの分類を行った。被験者には、センサ上方で各パターンに定義された方向および速度の動作を行ってもらい、その際のセンサ出力を記録した。

取得したデータに対して機械学習モデルを適用した結果、複数の動作パターンを安定して識別できることを確認した (表1)。特に、単一方向の動作だけでなく、斜め方向や速度差を含む動作についても、センサ出力の時系列的な違いを捉えることで識別が可能であることが示された。

表1 各モデルによる分類結果

モデル	評価指標			
	accuracy	precision	recall	F1_score
LR	0.8184	0.8183	0.8204	0.8177
KNN	0.9323	0.9284	0.9231	0.9317
SVC	0.9645	0.9649	0.9648	0.9647
RF	0.9251	0.9258	0.9252	0.9254

一方で、識別誤りが生じるケースも確認された。誤判定の多くは、動作方向が近接している場合や、動作速度の違いが曖昧な場合に集中しており、これはセンサ出力波形が類似した形状を示すことに起因すると考えられる。この結果は、容量型近接センサが人の動作の微妙な違いを敏感に反映する一方で、動作定義や実行方法のばらつきが結果に影響を与えることを示唆している。

これらの結果から、本方式は非接触での動作入力技術として十分な可能性を有している一方で、実用化に向けては動作定義の整理や学習データの充実が重要であることが明らかとなった。

### 5. おわりに

本稿では、3電極構成の3次元容量型近接センサユニットを用いた非接触動作入力技術について、その構造、出力特性、および機械学習を用いた動作識別の考え方を紹介した。容量型近接センサは、簡素な構成で人体の接近や移動を検出できる点に特徴があり、複数電極を用いることで方向性を持った情報を取得できる。

近年非接触インターフェースへの社会的要請が顕在化した背景のもと、単なる物理量検出に留まらない入力手段としてセンサを活用することが求められている。本研究で示したように、複数チャンネルの時系列信号を機械学習により処理することで、従来手法では対応が難しかった複雑な動作パターンに対しても柔軟な識別が可能となる。すなわち、機械学習技術を導入することで、センサは単なる検出素子から、人の意図を入力として扱える入力デバイスへと機能を拡張できる。

本方式は、センサ構成が簡素であるため、装置への組み込みや拡張が比較的容易であり、産業用途における非接触操作インターフェースへの応用が期待される。今後は、動作定義の最適化や学習データの拡充を通じて識別性能および汎化性能のさらなる向上を図るとともに、実際の使用環境を想定した評価を進めていく予定である。

### 参考文献

- 1) M. Deguchi: A simple method for detecting very small changes in capacitance or inductance, *Microelectronics Journal*, vol. 101, p. 104802, 2020.
- 2) M. Deguchi: Expansion of detectable area by floating electrodes in capacitive three-dimensional proximity sensor, *International Journal on Smart Sensing and Intelligent Systems*, vol. 14, pp. 1-11, 2021.
- 3) M. Deguchi, T. Kashiwao, M. Hiro, and K. Hayashi: 3D proximity sensing frame for non-contact operation panel, in *proceedings of the 8th IEEJ international workshop on Sensing, Actuation, Motion Control, and Optimization (SAMCON2022)*, vol. 14. Saitama University, Japan: The Institute of Electrical Engineers of Japan, 2022, pp. 252-256.
- 4) M. Hiro, K. Hayashi, T. Kashiwao, and M. Deguchi: Machine-learning based prediction of two-dimensional position coordinates for a proximity sensor, in *proceedings of 8th IEEJ International Workshop on Sensing, Actuation, Motion Control, and Optimization (SAMCON2022)*, vol. SS4-1, 2022, pp. 257-260.
- 5) T. Kashiwao, M. Hiro, K. Hayashi, and M. Deguchi: Machine-learning- based prediction of the three-dimensional (3d) position coordinates of 3D proximity sensing frames, *IEEJ Journal of Industry Applications*, vol. 12, no. 4, pp. 800-807, 2023.
- 6) K. Hayashi, T. Kashiwao, M. Hiro, and M. Deguchi: Hand motion classification in the 3D proximity sensors unit using machine learning, in *Proceedings of 9th IEEJ International Workshop on Sensing, Actuation, Motion Control, and Optimization (SAMCON2023)*, vol. TT7-1, 2023, pp. 579-582.
- 7) T. Kashiwao, K. Hayashi, M. Hiro, R. Ogino, and M. Deguchi: Machine learning-driven classification of hand motion for the 3D-proximity-sensors unit, *IEEJ Journal of Industry Applications*, vol. 13, no. 2, pp. 165-170, 2024.
- 8) R. Ogino, T. Kashiwao, K. Hayashi, Y. Yamamoto, K. Higeshiro, and M. Deguchi: Hand-motion classification based on machine learning for the 3D-proximity-sensors unit, in *Proceedings of SICE Festival with Annual Conference 2024*, 2024, pp. 438-441.
- 9) K. Higeshiro, R. Ogino, Q. Li, M. Deguchi, and T. Kashiwao: Hand-motion classification based on machine learning in three-dimensional capacitive proximity sensors, in *Proceedings of 11th IEEJ International Workshop on Sensing, Actuation, Motion Control, and Optimization (SAMCON2025)*, 2025, pp. 7-10.