

電子キーに搭載した加速度センサを用いた機械学習による人物の特定モーション検出

大竹 稔[†] 名和 佑記[†] 河村 大輔[†] 岩下 明暁[†] 山田 啓一[‡]

株式会社東海理化電機製作所[†] 名城大学[‡]

1. はじめに

近年、自動車には、電子キーのスイッチ操作やドアノブへのタッチ操作等をトリガーとした車両制御システム（ドア・トランクの解錠/施錠等）が導入されている。

我々は、ユーザの携帯する電子キー内に加速度センサを搭載し、SVM(Support Vector Machine)[1]を用いたユーザの特定モーション検出をトリガーとする、車両制御システム[2]を開発した。ユーザは、電子キーやドアノブを直接操作することなく、特定のモーションを行うことによって、車両を制御可能となる。

電子キーに組み込むマイコンには、計算能力やメモリ量により、使用可能な特徴量の種類や数に制約があるため、特徴選択が必要になる。しかし、SVMを用いての直接的な特徴選択は、計算コストが大きい問題がある。

本稿では、特定モーション検出の概要を述べると共に、そのために考案した計算コストを考慮した特徴選択手法とそれによる検出性能について報告する。

2. 特定モーション検出の概要

センサの加速度信号から、3STEP構成（STEP 1:静止判定，STEP2:特定モーション判定，STEP 3:静止判定）で特定モーションの検出を行う。

STEP1 と 3 は、閾値処理によるものである。STEP2 は、ルールベースによるセグメンテーションと、識別関数による特定モーション識別からなる。まず、特定モーション共通の加速度ピークパターンの閾値判定により、加速度信号のセグメンテーションを行う。次に、セグメンテーションされた各区分間について、その区分間の特徴量から特定モーションであるかを識別する。特定モーションは、携帯位置の制約がない両踵を同時に上げ下ろしする動き（以降、両踵タップ）とする。実装時に組み込む特徴量算出と識別関数は、3.3 で述べる手法によって定める。

3. 特定モーション識別

3.1 特徴量

特徴量は、対象区間から算出される、ピーク値（最大値/最小値）や平均値、ピーク to ピーク、区間長等の、計算コストが低い 57 個とする。さらに、57 個の 1 次特徴量から汎化性能の向上効果が期待できる 2 次（2 乗含む）特徴量を作成し、計 1710 個とする。

電子キーに搭載できるマイコンの計算能力及びメモリ量の問題から、識別器には線形識別関数（線形 SVM）を使用し、特徴量数は最大 50 個程度とする。そのため、特徴選択が必要になる。

3.2 特徴選択

1710 個の中から、50 個以下で最適な特徴量の組み合わせを、特徴選択により探索する。

SVM による特徴選択は、SVM 学習時の計算コストが高い。他方、相関係数など計算コストの低い手法を用いての特徴選択は、識別性能が低くなる問題がある。そこで、次に述べる、学習時の計算コストと性能を考慮した 3 段階の特徴選択手法（提案手法）を用いる。

3.3 提案手法

提案手法の特徴選択のフローを図 1 に示す。

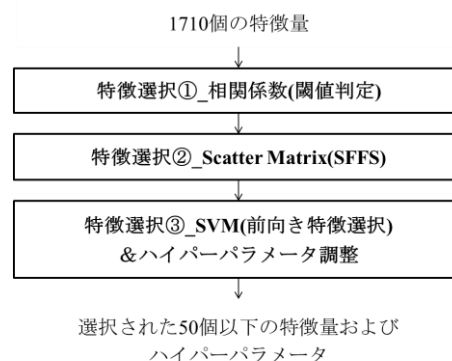


図 1 提案手法の特徴選択のフロー

特徴選択①：情報量が重複した特徴量は、いずれか 1 つで十分であり、後の特徴選択時の無駄な計算コストとなる。そのため、異なる特徴量同士の相関係数を算出し、閾値を 0.9 以上の明らかに傾向が類似している特徴量を削除する。

Detection of specific motion of a person based on machine learning using an acceleration sensor built in an electronic key device

[†]M.Otake, Y.Nawa, D.Kawamura, H.Iwashita, TOKAI RIKA.CO.,LTD

[‡]K.Yamada, Meijo University

特徴選択②：SVM よりも計算コストが低いクラス分離度（正例と負例のデータ分布の離れ具合）の指標として、フィッシャー線形判別分析の Scatter Matrix を使用する。ラッパー法の一つである SFSS(Sequential Forward Floating Selection) で特徴選択し、70 個とする。

特徴選択③：線形 SVM を用いて 50 個以下の最適な組み合わせを選択する。ハイパーパラメータにより最適な特徴量の組み合わせが異なるため、SVM による特徴選択とハイパーパラメータの探索は同時に行う。

特徴選択の指標は、誤検出率 0.1%の時の検出率とし、検出率が最大となる組み合わせをラッパー法の一つである前向き特徴選択により、探索する。なお誤検出率 0.1%は、開発システムの要求仕様から設定した。指標とする検出率等の性能値は、交差検証法とブートストラップ法を組み合わせた方法を用いて算出する。

4. 評価

提案手法の有効性を示すために、表 1 の 4 つの手法と比較し、評価を行った。比較手法は、最も高い性能が期待される線形 SVM による特徴選択を手法(a)とし、計算コストが高い順に手法(b)~(d)とした。

表 1 提案手法と比較手法条件

	特徴選択			ハイパーパラメータ調整
	相関係数	Scatter Matrix	線形SVM	
提案手法	○ (特徴量数指定なし)	70個	50個以下& ハイパーパラメータ調整	
手法(a)	-	-	50個以下& ハイパーパラメータ調整	
手法(b)	70個	-	50個以下& ハイパーパラメータ調整	
手法(c)	-	50個	-	ハイパーパラメータ調整のみ
手法(d)	50個	-	-	ハイパーパラメータ調整のみ

※出力特徴量数を指定したものは、個数を記入。

4.1 データ

ATR-promotions 製の小型無線多機能センサ TSND121 を使用し、電子キーの所持が想定される位置（ズボンポケット、バッグ等）の加速度を測定した。正例は 16 名分 726 データ、負例（1 歩だけ歩く等の両踵タップ以外の動作）は 23 名分 3511 データを収集し、これらを学習及び評価に用いた。

4.2 評価方法

評価指標には、学習時間比、判定性能を用いた。各評価指標の詳細を以下に示す。

学習時間比：50 個以下での最適な特徴量の組み合わせ算出までの時間と SVM のハイパーパラメータ調整時間の合計時間で、提案手法の時間を 1 とした時の比率。学習に使用した環境は、HP 製 Z420 Workstation と MATLAB(2015b)。

判定性能：誤検出率 0.1%時の検出率

4.3 評価結果

学習時間比：表 2 より、最も計算コストが低い手法(d)に対し、提案手法の計算コストは、約 14 倍で、最も計算コストが高い手法(a)に対し、約 1/24 であった。

判定性能：提案手法は、最も性能が高い手法(a)に対し 0.4%減、最も計算コストの低い手法(d)に対し 39.1%増となった。また、手法(b)に対し 12.3%増、手法(c)に対し 0.6%増であった。

以上より、提案手法は、最も高性能な手法(a)よりも計算コストを 1/24 に低減しつつ、性能差は 0.4%未満とほぼ同等であることが確認された。

表 2 評価結果

	学習時間比	判定性能	
		検出率[%]	誤検出率[%]
提案手法	1.00	99.4%	0.1%
手法(a)	24.45	99.8%	0.1%
手法(b)	0.74	87.1%	0.1%
手法(c)	0.47	98.8%	0.1%
手法(d)	0.07	60.3%	0.1%

4.4 考察

手法(b)の結果から、大幅に特徴数を削減する際は、クラス分類の指標を持った評価値を用いた手法（Scatter Matrix や SVM を用いた手法）での特徴選択が有効と考えられる。

提案手法と手法(c)を比較し、提案手法の方が 0.6%ほど高性能であるのは、Scatter Matrix で有効な特徴量の組み合わせと SVM で有効な特徴量の組み合わせの違いによるものと考えられる。

5. おわりに

電子キーに搭載した加速度センサによる特定モーション検出と、そのために考案した特徴選択手法について述べた。提案手法により、計算コストを抑えつつ、高性能が達成できる特徴選択が行えた。提案手法は、システム開発段階（アルゴリズムの改良等）における性能見積りに非常に有効と考えられる。

参考文献

[1]C.Cortes, V.Vapnik, "Support-vector networks," Machine Learning, 20 (3), 1995.
 [2] 染田ら, "遠隔操作システム," 日本国特許庁 公開特許公報, 特許第 6215669 号, 2017.