

高画素赤外線センサによる低計算量な宅内行動認識手法の提案

藤田 渉[†]八田 俊之[‡]三輪 祥太郎[§]三菱電機株式会社[†]三菱電機株式会社[‡]三菱電機株式会社[§]

1 はじめに

近年、高齢化社会の進展により、高齢者の一人暮らしが増えている [1]. このような背景の中、遠隔地にいる高齢者の安否確認を行うことができる見守りサービスが注目されている. 見守りサービスには様々な種類が存在するが、本稿では「高齢者の転倒などの異常事態を宅内に設置されたセンサにより認識し報知する見守りサービス」を対象に考える.

宅内に新たにセンサを設置することなく、また、プライバシーにも配慮することができるセンサとして、ルームエアコンに取り付けられている高画素赤外線センサを取り上げる. 赤外線センサを用いて、転倒を検知する見守りサービスを実現するためには、熱画像上の人の行動認識が必要である. ここで、「行動」とは立っている・座っている・動いているなどプリミティブな動作とする. 熱画像上の人が短時間で立位または座位から臥位に遷移した場合に転倒と判定する.

高画素熱画像上の人の高精度な行動認識手法については、従来、深層学習を用いた手法が提案されている [3]. しかしながら、深層学習を用いた手法は計算量が大きく、ルームエアコン上のマイコンでは動作しないという問題点がある. この問題点を解決するために、本稿では低計算量での実行が可能な宅内行動認識手法について提案する.

2 熱画像上の人の行動認識手法

本章では、熱画像上の人の行動認識手法について述べる. 熱動画の各フレームから画像特徴を抽出し、機械学習を用いて人の行動認識モデルを構築した. 下記の画像特徴 (計 54 個) を抽出した.

- 各フレームの熱画像の基本統計量 7 個 (画素値の合計, 標準偏差, 最大値, 最小値, 中央値, 歪度, ユニークな要素の個数)
- 1, 3, 5 つ前のフレームとの差分画像の基本統計量 (計 21 個)
- 大津の手法により取り出した人領域 (高温領域) の 11 個の特徴 (重心の x, y 座標, 1, 3, 5 つ前のフレームからの重心の移動ピクセル数, 面積, 傾き, 外接矩形の長辺) [3]
- 各フレームを 2 次元離散コサイン変換したあとの低周波部分の基底関数の係数 10 個 [4]
- 各フレームを 2 次元離散サイン変換したあとの低周波部分の基底関数の係数 5 個 [4]

機械学習手法には k 近傍法 (k -NN), サポートベクトルマシン (SVM), ランダムフォレスト (RF), 勾配ブースティング決定木 (GBDT) [2] を用いた.

3 宅内行動データセット

赤外線センサには、MeIDIR (型名: MIR8032B1) を用いた. MeIDIR を図 1 に示す. 画素数 32×80 pixels, フレームレートは 4 fps である. その他のスペックについては製品情報ページ^{*1}を参照のこと.



図 1 MeIDIR

人の行動を MeIDIR を用いて撮影し、宅内行動データセットを作成した. 行動として、立位にて動作 3 パターン { 静止・作業動作・歩行 }, 座位にて動作 2 パターン { 静止・作業動作 }, 臥位にて動作 1 パターン { 静止 } を実施した. 赤外線センサに対する人の角度を正面・側面・斜め 45 度の 3 パターンにわけ、2 名の被験者によ

A human behavior recognition using a high-resolution IR sensor in the home environment

[†] Wataru Fujita, Mitsubishi Electric Corporation

[‡] Toshiyuki Hatta, Mitsubishi Electric Corporation

[§] Shotaro Miwa, Mitsubishi Electric Corporation

^{*1} <https://www.mitsubishielectric.co.jp/semiconductors/products/icsensor/infraredsensor/index.html>

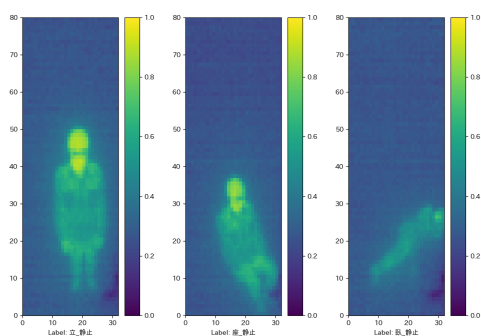


図2 撮影した熱画像例。左から立位・静止，座位・静止，臥位・静止の熱画像。

り各行動を約 10 秒間ずつ行った。撮影した熱画像例を図 2 に示す。各熱画像は、データセットにおける熱画像画素値の最小値・最大値により 0 から 1 の範囲で正規化した。データセットの全ての熱画像を目視で確認し、各熱画像に行動のラベルを付けた。人が写っていない熱画像に対しては「背景」のラベルを付けた。

宅内行動データセット計 5646 フレームを、時系列に沿って学習データ 2130 フレーム・検証データ 1870 フレーム・テストデータ 1646 フレームに分割した。データ拡張として、学習データにおいて左右フリップした画像を追加した。

4 評価実験

特徴選択

RF と GBDT では特徴重要度が計算可能である。54 個の画像特徴から重要度の高い特徴 7 つを選択した。RF, GBDT を用いて選択した特徴をサブセット 1, 2 する。また、学習データの特徴とラベルの相互情報量を算出し、情報量が多い 7 つの特徴を選択した。相互情報量を用いて選択した特徴をサブセット 3 とする。

評価 1：行動認識精度

学習データを用いて k-NN, SVM, RF, GBDT を学習し、検証データによりパラメータチューニングを行った。各モデルのテストデータでの行動認識精度を macro-F 値により評価した。評価結果を表 1 に示す。

評価 2：処理時間

特徴のセットのうち全特徴とサブセット 2 を取り上げる。処理時間計測には Raspberry Pi 3 Model B+ を用いた。全特徴とサブセット 2 を計算する時間を計測したところ、全特徴では 1160.6 msec, サブセット 2 では 133.2 msec であった。また、全特徴とサブセット 2 を

表 1 特徴の各サブセットにおける行動認識精度 (macro-F 値)

	k-NN	SVM	RF	GBDT
全特徴	0.740	0.702	0.820	0.873
サブセット 1	0.564	0.526	0.379	0.463
サブセット 2	0.710	0.709	0.761	0.880
サブセット 3	0.639	0.594	0.497	0.547

表 2 全特徴とサブセット 2 を用いたときの行動認識の処理時間 (単位: msec)

	k-NN	SVM	RF	GBDT
全特徴	34.7	24.2	125.5	30.2
サブセット 2	10.5	11.6	68.1	14.0

用いて各モデルで行動認識を行ったときの処理時間を計測した。結果を表 2 に示す。各モデルで行動認識の処理時間を計測したところ GBDT を用いた場合が精度と処理時間のバランスが良いことがわかった。

5 おわりに

本稿では、ルームエアコンに搭載された高画素赤外線センサを用いて、一人暮らしの高齢者の見守りサービスを実現するための行動認識手法を検討した。特徴選択・行動認識精度・処理時間の観点で行動認識に用いる機械学習モデルを比較し、GBDT が最も精度と処理時間のバランスが良いことがわかった。今後、宅内行動データセットを充実化し、実際の居住環境においても頑健な行動認識手法の検討を進める。

参考文献

- [1] 2019 年 国民生活基礎調査 I 世帯数と世帯人員の状況 <https://www.mhlw.go.jp/toukei/saikin/hw/k-tyosa/k-tyosa19/index.html>
- [2] Chen, Tianqi, et al. "Xgboost: extreme gradient boosting." R package version 0.4-2 (2015): 1-4.
- [3] Polla, Félix, et al. "Action recognition from low-resolution infrared sensor for indoor use: a comparative study between deep learning and classical approaches." 2019 20th IEEE International Conference on MDM. IEEE, 2019.
- [4] Tao, Lili, et al. "Home Activity Monitoring using Low Resolution Infrared Sensor." arXiv preprint arXiv:1811.05416 (2018).