

高齢者モニタリングのためのカメラ画像を用いた異常動作検出

学生員 関 弘 和 (東京大学)

正 員 堀 洋 一 (東京大学)

Detection of Abnormal Action Using Image Sequence for Monitoring System of Aged People

Hirokazu Seki, Student Member, Yoichi Hori, Member (The University of Tokyo)

Japan is now a serious aging society and this problem will be more serious in the near future. Therefore, engineering support for aged people is required. As an important example of such support, a monitoring system for aged people is proposed in this paper. This system automatically learns aged people's usual actions in a few days and detects his/her abnormal action by observing the room with a simple camera such as CCD camera.

At the learning stage, Self-Organizing Map(SOM) is used to realize automatic learning. For the detection method, Eigenspace Method is used which is excellent in compression of image data and calculation of the correlation among images. Parametric Eigenspace Method(PEM) is also used to detect abnormalities such as the speed of the action. Some results show the effectiveness of the proposed method.

キーワード : 高齢社会, 高齢者モニタリングシステム, 異常検出, 自己組織化マップ, 固有空間法, パラメトリック固有空間法

1. はじめに

我が国は現在、高齢者人口が全体の14%を越えた高齢社会であり、さらに2015年には4人に1人が65才以上の高齢者になると予想されている⁽¹⁾。諸外国と比較しても特に著しいこの高齢化現象は、少子化現象とも合間って、医療・介護の容量、高齢労働者の増加、社会全体の活気などさまざまな面に問題を引き起こすと考えられる。このような状況の中、高齢者に対する工学的な立場からの支援が必要不可欠である。

我々は、計測・制御の技術を基盤に高齢者や障害者を支援することを目指す「福祉制御工学」という分野を提唱しており、安全性、使いやすさ、安価、ロバスト性、小電力などをキーワードとして取り組んでいるが、本稿で述べる高齢者モニタリングシステムの研究もこれに基づいている。

本論文は、高齢者の部屋をカメラでモニタリングし、普段と違う非日常的な動きを検出する「高齢者モニタリングシステム」の実現を目指したものである。1995年の阪神淡路大震災の後、仮設住宅において一人暮らしの高齢者が孤独死し、何日も経ってから発見されるというニュースがあった。また、一人で暮らせるほど元気な高齢者でも自宅でいつどんなアクシデントが起こるか分からない。例えば脳卒中や心筋梗塞などの病気で急に倒れたり、あるいは家中の段差で転倒したり、浴槽で溺死したりする人は多く、家庭内の不慮の事故による高齢者の死者数は、交通事故による死者数を上

回っている(厚生省調べ⁽²⁾)。

高齢者の部屋をカメラでモニタリングし、普段と異なる様子を自動的に検出するシステムが実現できれば、すぐに家族や医療機関、福祉施設に通報でき、図1のようなネットワークを利用して高齢者を社会全体で守っていくためのケアシステムの中で大変有意義なものになる。

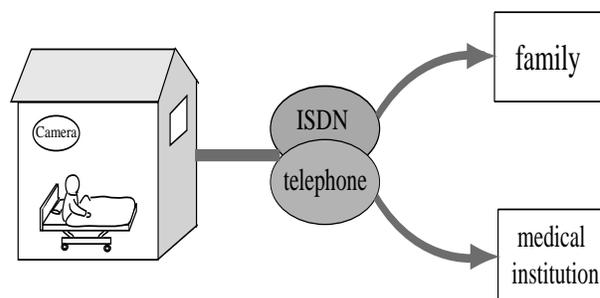


図1 高齢者モニタリングとケアシステム

Fig.1. Monitoring and care system for aged people.

高齢者のモニタリングに関する研究例として、我々が提案するような異常検出を主目的としたモニタリングとは別に、赤外線センサやおいセンサ等を用いて高齢者のふるまいを同定し、別居家族がおおまかな行動状況を把握することを目的としたモニタリングが考えられている⁽³⁾⁽⁴⁾。これらの研究では、高齢者にとっては、センサを通してどこかで誰かが自分の生活を見守ってくれているという安心感を得ることが可能であるとしている。

一方、本研究のように、異常検出を主目的としたものには、24時間健康状態を監視するために動脈血流を長時間連続的にモニタリングできる指輪センサ⁽⁵⁾、徘徊老人が屋外に進出したことを検知するシステム⁽⁶⁾、FG視覚センサをトイレ室内に設置し、気を失うなどの危機的状況を早期発見する監視システム⁽⁸⁾などの研究例がある。また、リアルタイムでの異常検出ではないが、傾斜センサを用いて転倒の頻度やその時刻を長時間計測するための老人転倒モニタの開発⁽⁷⁾なども行われている。

文献⁽⁹⁾は、行動パターンをモニタリングし、非日常的な行動を検出するという本稿と同様の目的意識のもと、HMMを用いた手法を提案しているが、全方位センサを用いている点で本稿と異なっている。

これまで特に企業を中心に、実用化に向けて異常検出システムが考えられてきたが、以下のようにそれぞれ多くの問題点が存在する。

- カメラを設置して、介護者がモニタ画面を見る
介護者が常に見ている必要があり、特に夜間では負担が大きい。
- 送信機等を内蔵したペンダントを携帯させて行動を把握外されると機能しない
- ベッド、照明、ドア、水道など部屋のあちこちにセンサを設置して様子を把握する
システム全体が大きなものとなり、コストも高くなり、容易に設置できるとは限らない

急激に高齢化が進む中で、できるだけ安価で設置しやすい装置を用いて異常検出を実現することが求められる。そこで、提案する異常検出システムはCCDカメラやテレビ電話のカメラをノートパソコン等につないだような安価で簡単なシステムを想定している。カメラを用いることで素早い検出が可能であり、通報があったときには画像によって正確に状況が把握でき、適切な対応ができる。

本論文では、日常的な動作・行動パターンの学習をした後、それに基づき非日常性検出を行うという一連の画像処理アルゴリズムを提案するが、モニタリングシステム全体として以下のような特徴をもつ。

- [1] 玄関やベッド、食卓の位置など、モニタリングする部屋に関する知識、また起床就寝時間や高齢者特有の行動特性のような人間行動学、心理学的な知識などはいっさい与えず、普段の様子を学習する。
- [2] システムは、高齢者が寝ている、トイレに行ったなどと動作の意味を理解することはなく、単に動作A,B,C,...などと分類するだけである。これはプライバシー保護にもつながる。
- [3] システムはある程度誤報があってもかまわない。それにより家族や医療機関とある程度の頻度でコミュニケーションをとることになればいいからである。

以上のように、カメラによる異常動作検出システムを実現するという、これまであまり例のなかった試みに対して、本論文は、基礎的研究としてその意義や位置づけを明確にする

とともに、検出のための一手法を提案するものである。

2. 画像系列を用いた人間の動作解析

2.1 動作解析法の例 画像系列から人間の動作、ジェスチャーを認識する研究はこれまで多く行われている。例えばDPマッチング⁽¹⁰⁾、HMM⁽¹¹⁾、Temporal Template⁽¹²⁾を用いたものがある。しかし本研究では、動作のパターン認識が主目的ではなく、学習パターンと異常パターンとの差異をいかに表現するかが重要な問題となる。

2.2 カメラで検出できる非日常性の分類 高齢者モニタリングを考えた場合について、カメラで検出できる非日常性を以下の4つに分類する。

(Ab-1) 学習画像にない動き

例えば急に倒れる動作など、学習したどの画像とも異なるようなものは異常と判断する。

(Ab-2) 動きの速さ

高齢者は普通ゆっくり動くはずであるので、ものすごく速い、あるいは遅い動きがあれば異常と判断する。例えば階段ですべり落ちる事故や他人(泥棒など)が侵入してきた様子はその速さで検出できる。

(Ab-3) 動きの方向

これは特に、工場で動くロボットや交通状況の監視で役立つ要素である。

(Ab-4) 行動パターン

例えば真夜中に外出したり、一日中寝ていたりするような、普段と異なる行動パターンも検出しなければならない。

2.3 画像間の距離の抽出 本研究では、動作の分類や異常検出において、画像間の距離をもって判断する。画像間の距離を抽出するために、画像間相関の計算と画像データの圧縮に優れた性質をもつ固有空間法⁽¹³⁾⁽¹⁴⁾を用いる。これは主成分分析の考えに基づいており、多数の多次元データから主要な成分を抽出し、データがもつ情報を縮約した本質的な低い次元軸で表現する手法である。この方法により、パターン認識による動作の分類も可能であり、また、非日常的な動きの画像は学習画像との相関が低いものであると考えたとき、画像間の距離によって異常検出が行える。

2.3.1 固有空間法 ここで、固有空間法を画像データに適用する場合の原理について述べる。1枚の静止画像を、次元 N の画像ベクトル $y_i (i = 1, \dots, I : I$ はサンプル数) で表す。各要素は各画素の濃度値を表している。

$$y_i = [y_1^{(i)}, y_2^{(i)}, \dots, y_N^{(i)}]^T \dots \dots \dots (1)$$

全サンプル画像ベクトル $y_i (i = 1, \dots, n)$ の平均 c

$$c = \frac{1}{I} \sum_{i=1}^I y_i \dots \dots \dots (2)$$

を計算し、次に各画像ベクトルから平均 c を差し引き、行列 Y を求める。

$$Y \equiv [y_1 - c, y_2 - c, \dots, y_n - c] \dots \dots \dots (3)$$

このとき、画像集合の共分散行列 Q は式(4)で表される。

$$Q \equiv YY^T \dots\dots\dots (4)$$

固有空間 (例えば k 次元) は、次の固有方程式

$$\lambda_i e_i = Q e_i \dots\dots\dots (5)$$

を解き、 k 個の大きい固有値 ($\lambda_1 \geq \dots \geq \lambda_k \geq \dots \geq \lambda_K$) に対応する固有ベクトル (e_1, \dots, e_k) を基底ベクトルとすることにより得られる。十分小さい固有値を無視することで、サンプル画像の次元を落とすことが可能となる。有効な次数の決定には、式 (6) の固有値寄与率 W_k と適当なしきい値 T_s を用いる。しきい値 T_s には 0.8 や 0.9 という値が用いられることが多い。

$$W_k = \frac{\sum_{i=1}^k \lambda_i}{\sum_{i=1}^K \lambda_i} \geq T_s \dots\dots\dots (6)$$

ここで 1 枚の画像 y_i (次元 N) は、式 (7) により次元 k の固有空間ベクトル (固有空間上の 1 点) へ投影される。

$$z_i = [e_1, \dots, e_k]^T (y_i - c) \dots\dots\dots (7)$$

本研究では、背景画像から人間の領域を抽出した 2 値画像を固有空間法に適用する。例えば図 2 のような 3 種類の画像集合 (各 10 枚、計 30 枚) を用いると、図 3 のように各画像の投影点が 3 箇所に分かれる固有空間が構築される。

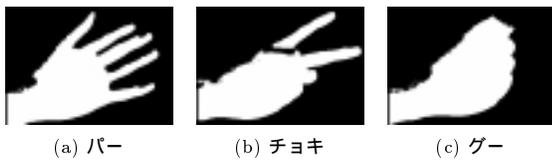


図 2 3 種類の学習画像
Fig. 2. Three kinds of sample images.

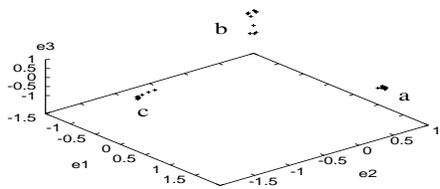


図 3 図 2 の画像からつくった 3 次元固有空間
Fig. 3. 3-dimensional eigenspace constituted from three kinds of sample images in Fig.2.

ここで、2 枚の画像 y_m, y_n が固有空間上の 2 点 g_m, g_n にそれぞれ投影されるとすると、その画像間の相関 $y_m^T y_n$ が大きければ固有空間上の 2 点間距離 $\|g_m - g_n\|$ は小さくなるのが数学的に示されている⁽¹³⁾。また、数万次元の画像データが数次元 (例えば 3 次元や 4 次元) ベクトルで表現されるため、4 桁ものデータ圧縮が可能である。よって、固有空間法は画像間相関の計算と画像データの圧縮において非常に優れた性質をもっているといえる。本研究では、学習にない異常な動作の画像は、学習画像との相関が低いと考え、学習画像の投影点との距離を測ることで異常性を検出する。

2.3.2 パラメトリック固有空間法 向きや大きさにおける連続的な画像の変化を考えた場合、連続する画像間の相関は高くなるため、その画像系列に対応した固有空間上の点集合は図 4 のようにスムーズな軌跡を描くことになる。

これは、固有空間法を発展させた手法としてパラメトリック固有空間法 (PEM)⁽¹³⁾⁽¹⁵⁾ と呼ばれる。パラメトリックに変化する画像を固有空間中の多様体で表現しようとする手法であり、パラメータとして対象物体のポーズ、光源の位置、時間などを用いることで⁽¹³⁾⁽¹⁵⁾、さまざまなパターン認識が可能となる。

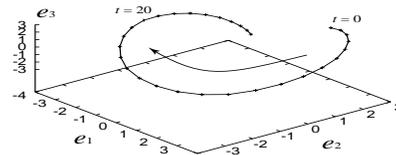


図 4 パラメトリック固有空間法
Fig. 4. Parametric Eigenspace Method.

2.4 非日常性検出の流れ 本研究では、固有空間法を用いて 4 種類の非日常性 (Ab-1)~(Ab-4) を検出する。

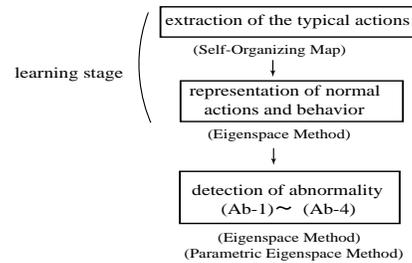


図 5 非日常性検出処理の流れ
Fig. 5. Process of non-daily action detection.

3. 正常な動作パターンの学習方法

3.1 自己組織化マップを用いた代表的な動作の抽出 高齢者の行動パターンを考えた場合、食卓やベッドなど、ある場所に留まっている時間は、移動する時間に比べてはるかに多い。そのため画像中のある位置に留まっていることが多く、それら何種類かの類似した画像が多く見られることになる。これらを代表的な動作として抽出する。

代表的な動作を自動的に抽出するための方法として、自己組織化マップ (SOM: Self-Organizing Map)⁽¹⁶⁾⁽¹⁷⁾ を用いる。これは教師なし学習で、学習データをクラスタに分類する方法である。自己組織化マップを用いた学習のアルゴリズムを以下に示す。ただし、図 6 のような Kohonen ネットワークを構成する 1 つの要素を「ユニット」と呼び、それぞれのユニットは、ネットワークへの入力データに対応する重みベクトルをもつとする。

[Step1] 初期化

各ユニットの重みベクトル $\{w_i, i \in \Omega\}$ をランダムに発生させる。

[Step2] 勝利ユニットを求める

入力ベクトル $x(t)$ ($t = 1, \dots, T$) に最も近い重みベクトル w_c をみつける。

$$\|x(t) - w_c\| = \min_i \|x(t) - w_i\| \quad \dots \dots \dots (8)$$

[Step3] 勝利ユニットとその周辺ユニットの更新

Step2 で見つかった勝利ユニットと近傍 $N_c(t)$ に入るユニットの重みベクトルを式 (9) で更新する。

$$w_i := \begin{cases} w_i + \alpha(t)(x(t) - w_i) & \text{if } c \in N_c(t) \\ w_i & \text{if } c \notin N_c(t) \end{cases} \quad (9)$$

$\alpha(t)$ は学習係数である。

Step2 に戻り、これを学習回数 $t = 1, 2, \dots, T$ について繰り返す。

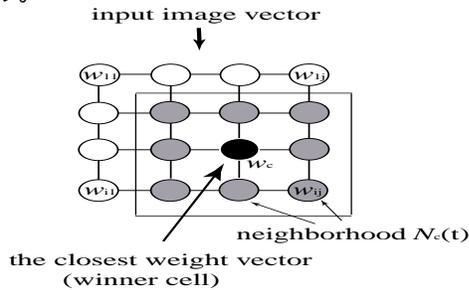


図6 2次元自己組織化マップ

Fig. 6. 2-dimensional Self-Organizing Map.

学習データの中に類似したベクトルが多数ある場合には、それぞれ隣接した領域に集まり、非常に類似した重みベクトルとして浮かび上がってくる。逆に、類似するものが少ないようなデータが写像されるユニットの周辺では、学習される頻度が少ないので、隣り合った重みベクトルは大きく異なったものとなる。

2次元マップの場合の各クラスタを抽出するためのアルゴリズム⁽¹⁸⁾を示す。これは上述の性質を利用したクラスタリング手法で、非常に類似した重みベクトルをもつユニット集合を1つのクラスタとみなす方法である。近傍 $D(i, j)$ の重みベクトルとの距離を式 (10) で定義する。

$$d(i, j) = \frac{1}{|D(i, j)|} \sum_{(u, v) \in D(i, j)} (w_{i, j} - w_{u, v})^T (w_{i, j} - w_{u, v}) \quad \dots \dots (10)$$

この値が小さいものを見つけることで、学習頻度の高い画像ベクトルを抽出する。 $d(i, j)$ を2次元のユニットすべてについて求めたものをクラスタマップとよぶ。

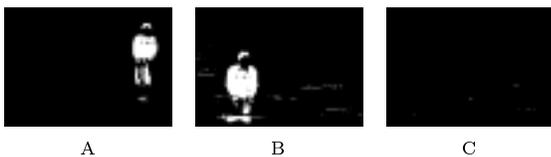
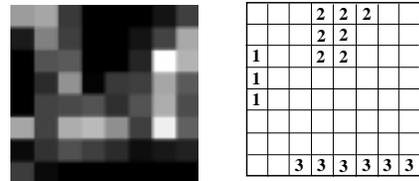


図7 3種類のサンプル画像

Fig. 7. Three kinds of sample images.

例えば図7のような3種類の代表的な画像を含む系列(240枚)を自己組織化マップで学習するとする。各画像は、A:画面右端に立っている、B:画面左下で椅子に座っている、C:外出中であつたり、お風呂やトイレに行つて画面に映っていない、を表している。クラスタマップとクラスタリング結果は図8(a),(b)のようになり、3種類の画像が抽出できる。なお、クラスタマップは、各ユニットにおける $d(i, j)$ の値を画素値とする画像で表現した。



(a) クラスタマップ (b) クラスタリング結果

図8 代表的な画像の抽出

Fig. 8. Extraction of three typical images.

$d(i, j)$ の値が小さい16個のユニットに対してラベルづけを行ったが、各クラスタの重みベクトルを画像で表現すると図9のようになる。

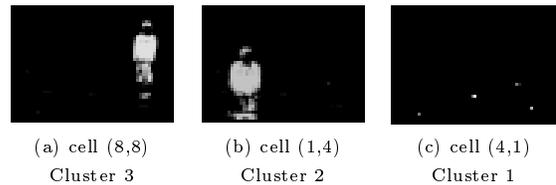


図9 各クラスタの重みベクトル

Fig. 9. Weight vectors of each cluster.

3.2 固有空間法による動作の分類 自己組織化マップにより抽出した代表的な動作の画像ベクトル、つまりクラスタマップでラベルのついたユニットの重みベクトル16個から固有空間を構築すると図10のようになる。3種類の動作を分類できる固有空間がつくられていることがわかる。これにより学習画像全てから固有空間をつくり、その投影点をクラスタリングする場合のように膨大な計算をする必要はなくなる。

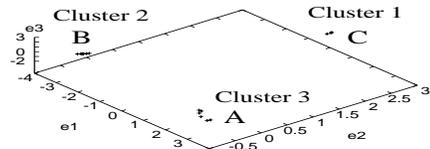


図10 ラベルのついた16個の重みベクトルからつくった3次元固有空間

Fig. 10. 3-dimensional eigenspace constituted from sixteen labeled weight vectors.

入力画像はこの固有空間上に投影され、動作の分類が行われる。図11は全学習画像を式(11)により空間上に投影した結果を示す。

$$z(t) = [e_1, \dots, e_k]^T (y(t) - c) \quad \dots \dots \dots (11)$$

A から B へ移動すると、固有空間上では A から B へ直線的には移らず、いったん C を経由する。これは A と B の間の領域では固有ベクトルが 0 であり、式 (11) を計算しても何も映っていない画像を投影したのと同じになるからである。

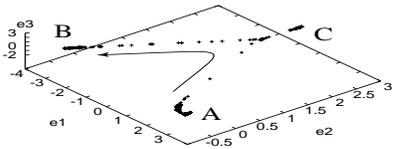


図 11 全学習画像の投影

Fig. 11. Projection of all reference images.

これらの投影点に対し、16 個の投影点との最小距離

$$d_1^2 = \min_i \|z(t) - f_i\|^2 \dots\dots\dots (12)$$

を求めることで動作 A, B, C と分類する。図 12 は全学習画像を固有空間上に投影し最小距離 d_1 を求めた結果である。

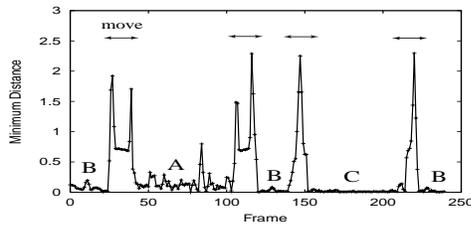


図 12 3次元固有空間上での最小距離 d_1

Fig. 12. Minimum distance in the 3-dimensional eigenspace d_1 .

A, B, C のいずれかの動作をしているときは最小距離 d_1 は小さい。一方、A から B、B から C へと移動しているときは、 d_1 は大きくなる。このことを用いて高齢者が移動しているときの画像も抽出することができる。

3.3 2段階固有空間法による動作解析 異常を検出する際、寝ている、食事している、歩いているなどの動作それぞれで詳しい解析を行うため、動作の行われる画像中の局所的な領域に固有空間法を適用することにする。固有空間法は画像のグローバルな特徴をとらえる手法であるので⁽¹⁴⁾、局所領域での解析が有効である。

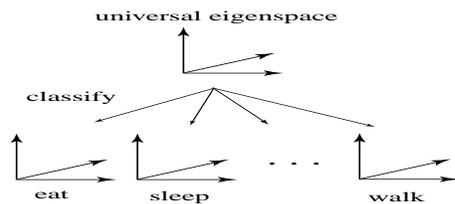


図 13 2段階の固有空間法

Fig. 13. 2-step Eigenspace Method.

つまり、図 10 のような 1 段階目の固有空間 (以後、ユニバーサル固有空間とよぶ) 上で動作の分類を行い、2 段階目の動作ごとの固有空間上でそれぞれ詳しい解析を行うという、2 段階の固有空間法で動作の分類、異常動作検出を実現する。

3.4 動作ごとの注目領域の決定方法 動作ごとの注目領域の決定には、動作の分類に利用した自己組織化マップの重みベクトルを用いる。人間の領域が中心に来るような領域をもうけるため、濃淡値を重みにした加重平均をとって中心画素を計算する。その後、中心画素から徐々にウィンドウを広げていき注目領域を決定する。



(a) (8,8) の重みベクトル (b) 注目領域

図 14 動作ごとの注目領域の決定

Fig. 14. Decision of the focused regions.

3.5 正常な動作パターンの表現 正常な動作パターンは固有空間上の投影点により表現される。詳しく述べると、[同じ場所での動作]

→ 動作ごとの固有空間上の投影点集合

[移動する動き]

→ パラメトリック固有空間上の投影点列 (軌跡)

[行動パターン]

→ ユニバーサル固有空間上の投影点に添付する時間情報

4. 非日常的な動きの検出

4.1 学習にない動きの検出 (Ab-1) 上述のように、固有空間上の距離は画像間の相関を表すので、学習にない異常な動きを固有空間上の距離の大きさで検出する。動作 j について、学習画像の投影点 $f_i^{(j)}$ と入力画像の投影点 $z^{(j)}(t)$ との最小距離を

$$d_2^2 = \min_i \|z^{(j)}(t) - f_i^{(j)}\|^2 \dots\dots\dots (13)$$

により計算し、これが大きくなれば異常と判断する。

図 15(a) のように椅子に座っている画像を学習し、図 15(b)(c) のように椅子から倒れる画像 ($t = 11$ 以降) を入力すると、3 次元固有空間上の軌跡と最小距離 d_2 は図 16、図 17(a) のようになる。



(a) 学習画像の例 (b) 入力画像 ($t = 15$) (c) 入力画像 ($t = 19$)

図 15 学習画像と入力画像

Fig. 15. Reference and input images.

固有値寄与率が 0.87 になる 5 次元空間での最小距離 d_2 を図 17(b) に示す。倒れ始めた $t = 11$ 以降に d_2 が大きくなることからわかる。これらの結果から、2 値画像と固有空間法の組み合わせで十分、非日常動作検出が行えると言える。

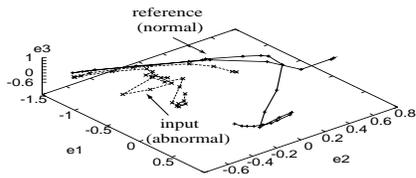


図 16 3次元固有空間上の軌跡

Fig. 16. Loci in the 3-dimensional eigenspace.

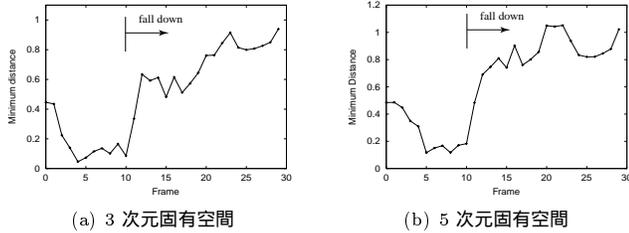


図 17 固有空間上での最小距離 d_2

Fig. 17. Minimum distance in the eigenspace d_2 .

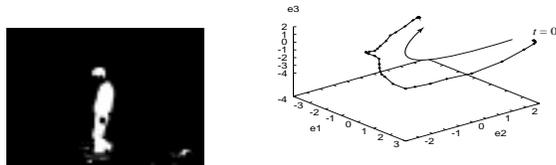
4.2 動きの速さと方向の検出 (Ab-2)(Ab-3) 先程のような単なる投影点どうし、つまり静止画像どうしの比較では動きの速さや方向は検出できない。そこで、パラメトリック固有空間法⁽¹³⁾⁽¹⁵⁾を用いて軌跡どうし、つまり動画像どうしの比較を行う。動画像間の距離を式(14)のように、固有空間上の軌跡間の距離で定義する。

$$d_3^2 = \min_{a,b} \sum_{t=0}^T \|z^{(j)}(t) - f^{(j)}(at+b)\|^2 \dots\dots (14)$$

$$\tilde{a} = \arg \min_a \sum_{t=0}^T \|z^{(j)}(t) - f^{(j)}(at+b)\|^2 \dots (15)$$

a は時間伸縮、 b は時間シフトのパラメータである。この2つのパラメータを導入して、入力画像系列の投影軌跡 $z^{(j)}(t)$ に最も近くなるような学習画像系列の投影軌跡 $f^{(j)}(at+b)$ の部分集合を見つける。最小距離をもつ軌跡を求めたときの時間伸縮 \tilde{a} に注目すると、その絶対値は速さを、符号は方向を表すと考えられる。

- if $\tilde{a} < -1$, 反対方向で速い動き
- if $-1 \leq \tilde{a} < 0$, 反対方向で遅い動き
- if $0 \leq \tilde{a} < 1$, 同じ方向で遅い動き
- if $1 \leq \tilde{a}$, 同じ方向で速い動き



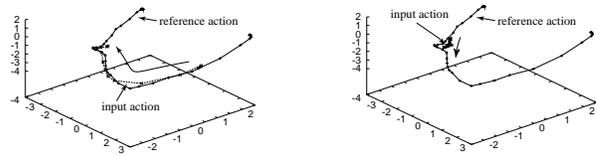
(a) 学習画像例 (b) 3次元固有空間上の軌跡 (学習パターン)

図 18 歩く動作の学習

Fig. 18. Learning of walking action.

図 18(a) のように画像の右から左に歩く画像を学習すると、3次元固有空間上では図 18(b) のような軌跡を描く。

このとき、(I) 学習と同じ方向で速い動き、(II) 学習と反対方向で遅い動き、の画像系列を入力すると、固有空間上の軌跡はそれぞれ図 19 のようになる。



(I) 同じ方向で速い動き (II) 反対方向で遅い動き

図 19 3次元固有空間上の軌跡

Fig. 19. Locus in the 3-dimensional eigenspace.

表 1 式(14)の計算結果

Table 1. Calculation results of Equation 14.

k	(I)			(II)		
	\tilde{a}	\tilde{b}	d_3	\tilde{a}	\tilde{b}	d_3
3	1.39	6.57	3.20	-0.17	27.26	1.15
5	1.48	6.34	3.93	-0.30	27.12	2.62
7	1.50	6.18	4.55	-0.39	27.52	3.40
8	1.54	5.82	4.77	-0.40	27.54	3.63

固有値寄与率が0.86になる8次元固有空間までの \tilde{a} の値は表1のようになる。動きの速さと方向が \tilde{a} により推定されることがわかる。

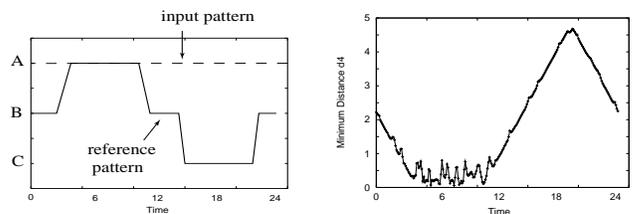
4.3 非日常的行動パターンの検出 (Ab-4) 真夜中に外出する、一日中寝ている、というような非日常的な行動パターンを検出するために、式(16)により新しい距離の定義をし、動作の分類の際に異常パターンを検出する。この距離は、学習したユニバーサル固有空間上の投影点に添付した時間情報 t_i と入力時刻 t との差 d_t を、式(12)で求める固有空間上の距離 d_e に付加したものである。

$$d_4 = \min_i \sqrt{c_1 d_e^2 + c_2 d_t^2} \dots\dots\dots (16)$$

$$d_1^2 = \|z(t) - f_i\|^2, \quad d_t^2 = (t_i - t)^2$$

c_1, c_2 はそれぞれ d_e^2, d_t^2 に対する重みである。

図 20(a) のような行動パターンを学習したとき、一日中 A にいるパターンを入力すると、最小距離 d_4 は図 20(b) のようになる。重みはそれぞれ $c_1 = 1, c_2 = 0.3$ とした。



(a) 学習した行動パターン (b) 最小距離 d_4

図 20 異常な行動パターンの検出

Fig. 20. Detection of abnormal behavior pattern.

A にはいるはずの時間帯では d_4 は小さいが、B,C どちらかにいるはずの時間帯に A にいると、 d_4 は大きい値になり、異常な行動パターンとして検出できる。 c_2 の値を小さくすることで、多少の行動パターンのずれ(起きる時間がいつもより少し遅い、食事の時間が少し変わったなど)は許容することができる。

5. ま と め

本論文では、計測・制御の技術を基盤に高齢者や障害者を支援することを旨とする「福祉制御工学」の一研究として、高齢者の部屋をカメラでモニタリングし、普段と異なる非日常的な動作や様子を検出する方法を提案した。

カメラによるモニタリングで高齢者の非日常的な動作を検出するという、これまであまり例のなかった試みに対して基礎的研究を行ったが、ここで示した手法をそのまま用いて実際に高齢者に起こり得る全ての非日常性を検出できるとは限らない。今後、学習段階、動作の分類、異常検出段階それぞれにおいて手法の改良やさまざまな環境・条件下での実験的考察と定量的評価が必要であることは言うまでもない。しかし、これまでになかった新しい異常検出システムとして、その意義や位置づけを含めて基本的なメドを立てることはできた。本研究で提案した固有空間法を用いた手法も、あくまで検出のための一手法ではあるが、これによりある程度の非日常性検出が実現できるという可能性を示すことができたと言える。

本研究では、画像情報における非日常性を画像間の相関値としてとらえ、その計算に優れた性質をもつ固有空間法を用いて、動作の分類、異なる動きの検出、さらに速さと方向の検出にも適用した。学習段階では、教師なし学習法の一つである自己組織化マップ(SOM)により、寝ている、食事しているなど頻繁に行われる動作を抽出し、SOMの重みベクトルから固有空間を構築することで行動パターンの学習とその分類を実現した。異常検出段階では、動作ごとの固有空間上で、投影点間の距離を用いて学習と異なる動きを、またパラメトリック固有空間法(PEM)を用いて動きの速さなどの検出を行った。さらに時間軸の距離を重みをつけて固有空間上の距離と組み合わせた新しい距離により、一日中寝ているなどの非日常的な行動パターンの検出も行った。

本研究では人物のシルエットを切り出した2値画像を得るために、背景画像を差し引く方法を用いたが、背景や照明条件、洋服などの条件によってはうまく抽出できないことがある。実際には時空間フィルタや孤立点除去等の前処理を行う必要があると考えられる。また、オプティカルフローやエッジを用いた抽出手法⁽¹⁹⁾の適用なども今後の課題である。さらに極端な場合、夏と冬で洋服などの影響で対象者のシルエットの形そのものが変わってしまうことがありうるが、学習期間を長くすることで解決されうるであろう。

この固有空間法を用いた異常検出手法は、高齢者モニタリング以外にも、工場内の産業用ロボットや交通状況、病院の患者のモニタリング、防犯カメラ等への適用も考えられる。

(平成13年3月26日受付, 同13年8月23日再受付)

文 献

- (1) 国立社会保障・人口問題研究所, 日本の将来推計人口(平成9年1月推計).
 (2) 厚生省: “平成9年人口動態統計上巻”.

- (3) 品川佳満, 岸本俊夫, 谷川智宏, 難波克司, 井筒岳, 太田茂: “赤外線センサによる独居高齢者の在宅行動モニタリングシステム”, 第16回ライフサポート学会講演予稿集, pp.18 (2000).
 (4) 沢田史子, 大藪多可志, 南戸秀仁, 辻隆之: “マハラノビスの距離による居住者のふるまい同定”, 第16回ライフサポート学会講演予稿集, pp.19 (2000).
 (5) B.-H. Yang, S. Rhee and H. Asada: “A Twenty-Four Hour Tele-Nursing System Using a Ring Sensor”, Proc. of IEEE International Conference on Robotics and Automation, pp.387-392 (1998).
 (6) 保坂良資: “移動体通信網による簡便な徘徊老人屋外進出検知システムの評価”, 第16回ライフサポート学会講演予稿集, pp.59 (2000).
 (7) 吉村拓巳, 堀内郁孝, 東祐二, 中島一樹, 藤元登四郎, 千原國宏, 田村俊世: “老人転倒モニタの開発とその評価”, 電気学会論文誌C, Vol. 120-C, No. 12, pp.1846-1853 (2000).
 (8) 青木広宙, 中島真人: “FG 視覚センサを用いたトイレ用監視システム”, 画像ラボ, pp.1-5 (2000. 1).
 (9) 青木茂樹, 大西正輝, 小島篤博, 岩橋由雄, 福永邦雄: “人物の行動パターンに注目した異常通知システム”, 電子情報通信学会技術報告, PRMU2000-220, pp.139-146 (2001).
 (10) 高橋勝彦, 関進, 小島浩, 岡隆一: “ジェスチャー動画のスポットティング認識”, 電子情報通信学会論文誌, Vol. J77-D-II, No. 8, pp.1552-1561 (1994).
 (11) J. Yamato, J. Ohya and K. Ishii: “Recognizing human action in time-sequential images using Hidden Markov Models”, Proc. of IEEE Conference on Computer Vision and Pattern Recognition, pp.379-387 (1992).
 (12) J. W. Davis and A. F. Bobick: “The Representation and Recognition of Human Movement Using Temporal Templates”, Proc. of IEEE Conference on Computer Vision and Pattern Recognition, pp.928-934 (1997).
 (13) H. Murase and S. K. Nayar: “Visual Learning and Recognition of 3-D Objects from Appearance”, International Journal of Computer Vision, Vol. 14, pp.5-24 (1995).
 (14) 松山隆司, 久野義徳, 井宮淳: “コンピュータビジョン: 技術評論と将来展望”, 新技術コミュニケーションズ (1998).
 (15) H. Murase and R. Sakai: “Moving object recognition in eigenspace representation: Gait analysis and lip reading”, Pattern Recognition Letters, Vol. 17, pp.155-162 (1996).
 (16) T. Kohonen: “The Self-Organizing Map”, Proc. IEEE, Vol. 78, No. 9, pp.1464-1480 (1990).
 (17) 高村松三, 小平一穂: “Kohonen ネットワークによるごみ焼却炉の画像処理”, 電子情報通信学会論文誌 (D-II), Vol. J80-D-II, No. 7, pp.1722-1729 (1997).
 (18) 田中雅博, 古河靖之, 谷野哲三: “自己組織化マップを利用したクラスタリング”, 電子情報通信学会論文誌 (D-II), Vol. J79-D-II, No. 2, pp.301-304 (1996).
 (19) 前泰志, 白井良明, 三浦純, 久野義徳: “オプティカルフローとエッジを用いた複雑背景下での移動物体の追跡”, 日本ロボット学会誌, Vol. 15, No. 1, pp.103-108 (1997).

関 弘 和 (学生員) 1975年9月5日生。1998年大阪大学

基礎工学部システム工学科卒業。1998年4月東京大学大学院工学系研究科電気工学専攻修士課程入学、2000年3月修了。2000年4月同大学院博士課程入学、現在に至る。主として計測、制御工学に基づく高齢者支援、福祉制御工学に関する研究に従事。計測自動制御学会、日本ロボット学会などの会員。

堀 洋 一 (正員) 1978年東京大学工学部電気工学科卒業、

1983年同大学院博士課程修了。助手、講師、助教授を経て、2000年2月より電気工学科教授。専門は制御工学とその産業応用、とくに、モーションコントロール、メカトロニクス、電気自動車などの分野への応用研究。最近福祉制御工学を開始。1993年IEEE Trans. on IE 最優秀論文賞、2000年電気学会論文賞などを受賞。電気学会、計測自動制御学会、IEEE、日本ロボット学会、日本機械学会、自動車技術会などの会員。