

自己相関特徴とコヒーレンスに基づく推定手法を用いた 転倒防止のための起床動作検出

Detect Getting-up Behavior for Fall Prevention with a Vision Sensor

井上 円† Madoka Inoue 田口 亮‡ Ryo Taguchi 梅崎 太造† Taizo Umezaki

1. まえがき

65 歳以上の約 30[%], また老人ホームや高齢者施設で生活する高齢者においては, 半数以上が毎年転倒し, そのうちの半数以上は繰り返し転倒を起こしている. 更に 10 人に 1 人は, 大腿骨の骨折やその他の骨折, 硬膜下血腫などの深刻な怪我をしている [1]. 国内の調査でも, 病院などの施設で生活する高齢者の約 60[%]が転倒を起こすという結果が報告されている [2].

近年, 転倒を検知する枠組みとして, 加速度センサや RFID, 緊急通報用ボタンを用いたシステム等が開発されている. しかし, これらのシステムは電池を使用するために定期的なメンテナンスが必要となるなどの問題を含んでいる. 転倒が発生した際に電池が切れていると深刻なアクシデントに繋がる. そのため, 高齢者が入居する施設などは, 設備管理に非常に大きな責任を負うことになる. 更に, 高齢者はしばしばセンサや通報用ボタンなどの装着を忘れることがある. 転倒ボタンに関しては転倒後に高齢者が意識を失うケースでは役に立たない.

画像認識技術は, 前述の問題を改善する新しい転倒検出の手法を提案している. Qingcong は, 動画シーケンスから部分隠れと姿勢の多様性を考慮した転倒検出手法を開発した [3]. Caroline らは, 単眼カメラによる転倒検出手法を開発した. 頭部軌跡を 3 次元で追跡し, 3 軸方向の速度を用いることで日常動作から転倒を見分ける [4]. しかしながら, これらの手法は転倒自体を検出するアプローチであり, 転倒そのものを防止することはできない.

Brown J.S は, 頻尿や夜間頻尿, またはトイレに急いで駆け込むような際に骨折を伴う転倒が発生する傾向が強いという調査結果を報告している [5]. 最も頻繁に転倒が発生するシーンとしては, 病室に備えられた簡易トイレからベッドに戻る際や, ソファやベッドからトイレに移動する際とされている. そのため, 我々は転倒を事前に防止する効果的な手段として, 患者がトイレに行く際のベッドからの起き上がり動作をトリガーとして, 看護者に通知をおこなえるシステムを検討する.

BingBing らは, 深度センサと可視画像センサを備えた Microsoft Kinect デバイスと, 患者の起き上がり動作を検知する手法を組み合わせた新しい提案をした [6]. 深度センサは, 動画シーケンスから行動を推定するのに効果的な結果をもたらしている [7][8]. Kinect は深度情報を獲得する効果的で経済的なデバイスとして知られており, 転

倒検知に関する研究でもしばしば用いられている [9][10]. Kinect はセンサ前方に赤外波長近辺の非可視光をランダムな微小ドットパターンで撒布し, 投影されたパターンの反射を赤外線カメラで検出する [11]. そのため, 赤外波長を照射するデバイス部分は, 赤くちらついて見える. 一方, 転倒のリスクが高いとされる高齢患者は, せん妄や痴呆, また精神的に不安定な症状を示すことが多い [12]. それらの症状は, 不眠症や天井の様子が虫に見えるなどの幻覚を引き起こすことが報告されている [13][14]. 看護・介護環境においては, 音や光などを発する機材の導入は非常に慎重に検討する必要がある.

本研究では, 患者に対する負担が少なく, 経済的にも実用が容易な単眼カメラを用いた起き上がり動作の検出手法を提案する. 我々の提案手法は, エッジの勾配強度と勾配方向から得られた自己相関特徴を基に構成される. 動画シーケンスの局所領域から得られた特徴を基に AdaBoost 識別器を構築する. 自己相関特徴は Cubic High order Local Auto-Correlation (以後 CHLAC とする)特徴の考え方を基礎としている [15]. CHLAC は, 1)位置不変性(画像の中の物体の位置に結果が依存しない), 2)加法性(画像の中に対象物体が 2 つ出現した際に, それらの結果を加算した結果が得られる)という特性を持つ. そのため, 我々が提案する自己相関特徴も, 位置不変性と加法性という特性を引き継いでいる. 病院で用いられるベッドは一般的にキャスターが備え付けられており, 位置不変性という特性が効果的に働くと考えられる. また, 加法性という特性は, 将来的に 1 台のカメラで複数の患者の見守りに繋がると考えられる.

更に, 実験で得られた自己相関特徴は出力値に周期的な規則性を含んでいる. 出力値の周期性を用いることで特定の動作を効果的に推定できるか検討した. 周期性の効果の検討については, 動作認証などで研究がなされているコヒーレンスを用いる [16].

2. CHLAC

従来技術として, 行動推定や異常行動の特定などに用いられる CHLAC 特徴について述べる.

2.1 自己相関

自己相関とは, 信号処理において時間または空間のシフトにより得られる自身の信号との整合度合いを測る尺度であり, 自己相関は式(1)で表される.

$$X(a) = \int f(r)f(r+a)dr \quad (1)$$

r は起点位置, $f(r)$ は位置 r における出力, a は r からのラグ, $f(r+a)$ は位置 $r+a$ における出力を表す.

† 名古屋工業大学情報工学専攻, 愛知県
Science and Engineering, Nagoya Institute of Technology, Gokiso-cho,
Showa-ku, Nagoya, Aichi, Japan 466-8555

‡ 名古屋工業大学産業戦略専攻, 愛知県
Master of Techno-Business Administration, Nagoya Institute of
Technology, Gokiso-cho, Showa-ku, Nagoya city, Aichi, Japan 466-8555




図 1 CHLAC 特徴の概要




図 2 次数における特徴パターン数

2.2 立体高次局所自己相関 (CHLAC)

立体高次局所自己相関とは、2.1 項で述べた自己相関を時系列の画像データに適応した処理である。位置不変性と加法性という特性を備えることが知られており、人の動作のように時空間を連続的に変化する動きの性質を捉える上で好ましい定式とされている。

CHLAC 特徴の算出式を式(2)に示す。

$$X(a_1, a_2, \dots, a_N) = \int_{W \times H} f(r) f(r+a_1) \dots f(r+a_N) dr \quad (2)$$

r は基準点の位置、 $f(r)$ は位置 r における輝度値、 a は時刻と XY 平面で構成された 3 次元空間における基準点 r からの変位、 $f(r+a)$ は変位点 $r+a$ における輝度値、 N は変位点の数 (次数)、 W は画像幅、 H は画像高を表す。

図 1 のように時刻毎に連続フレームが与えられた場合、CHLAC 特徴の算出は、基準フレームとその時刻の前後におけるフレームから算出される。図 1 により定められた位置を基準点と置き、近傍の格子をマスクエリアとした場合、前後フレームの同じ位置もマスクエリアとして定める。つまり図 1 の例では、マスクエリアは時間軸と XY 軸の 3 次元で示した空間において立方体を形成している。マスクパターンの次数を 2 とした場合、基準点 以外の 2 点を変位点として、予め定められたマスクパターンに従い選択する。更に、基準点と変位点の 3 点から求めた自己相関が特徴量となる。

CHLAC 特徴のマスクパターン数は、マスクパターンを構成するブロックサイズを $W \times H$ 、フレーム区間を T 、次数を N とした場合、式(3)により求まる。

$$\text{マスクパターン数} = 1 + \sum_{n=1}^N W \times H \times T - 1 \times C_n \quad (3)$$

ただし、式(3)に示すマスクパターン数はパターンの重複を含む次数であり、実際の計算に用いられるマスクパターン数は、得られたマスクパターン数から画像操作時に平行移動等価となる組み合わせを除いたものであり、次数 2 の場合を例として算出すると、 $N=0$ 次が 1 個、




図 3 提案手法における特徴の抽出概要

$N=1$ 次が 13 個、 $N=2$ 次が 237 個、合計 251 パターンの組み合わせとなる[17]。

マスクパターンの次数を増加させた場合のマスクパターンの組み合わせは、理論上は図 2 に示すように指数関数的な増加傾向を示す。ただ、次数 2 におけるマスクパターンの定義も 251 パターンに及び、その実装が困難になるため、次数 2 を超えるマスクパターンの定義においても実装が困難であることが予想される。

3. 提案手法

提案手法は、連続フレーム画像から輝度勾配のフレーム間差分情報を算出し、算出した輝度勾配差分の自己相関を単純なマスクパターンで定義したものを特徴量とする。画像のエッジ情報を組み込むことで特徴量の表現能力を向上させることで、単純な記述のマスクパターンを用いた場合でも性能を維持することができると考える。特徴抽出の過程として、初めに連続 4 フレームの画像情報から低レベル特徴量として 3 フレーム分の輝度勾配ヒストグラムの差分情報を抽出する。続いて、ミドルレベルの特徴量として輝度勾配ヒストグラムの差分から自己相関特徴を獲得する。最後に、自己相関特徴から AdaBoost を用いた統計情報を得る。図 3 に特徴抽出の概略を示す。

3.1 Low-Level 幾何学特徴

画像の各点において、近隣画素で輝度勾配ヒストグラムを生成する。本アプローチでは、画像から勾配方向を算出するステップは次のようになる。初めに、各点の (x, y) 座標から角度方向を算出する。

$$m(x, y) = \sqrt{d_x(x, y)^2 + d_y(x, y)^2} \quad (4)$$

$$\theta(x, y) = \tan^{-1} \left(\frac{d_y(x, y)}{d_x(x, y)} \right) \quad (5)$$

$\theta(x, y)$ は角度方向、 $m(x, y)$ は勾配強度を表す。また $d_x(x, y)$ 並びに $d_y(x, y)$ は輝度差であり、次の式で算出される。

$$d_x = I(x+1, y) - I(x-1, y) \quad (6)$$

$$d_y = I(x, y+1) - I(x, y-1) \quad (7)$$




図4 提案手法における自己相関特徴の抽出概要

ここで、 $I(x, y)$ は、 (x, y) 座標上の輝度を表す。

続いて、 θ をビン数 K の勾配ヒストグラム $h_K(x, y)$ に畳み込む。 $h_K(x, y)$ は $S \times S$ ピクセル領域内の全ての画素の角度情報 θ を集計して得られる。

勾配ヒストグラムのビンのインデックスを k とすると、各ビンのスコア $h_k(x, y)$ は、式(8)で表される。

$$h_k(x, y) = \sum_{j=-(S-1)/2}^{(S-1)/2} \sum_{i=-(S-1)/2}^{(S-1)/2} m(x+i, y+j) \times \delta[k, \theta'(x+i, y+j)] \quad (8)$$

$\theta'(x, y)$ は、角度方向 $\theta(x, y)$ を K ビンに畳み込んだ値、 $\delta[\cdot]$ はクロネッカーのデルタを表し、仮に k と $\theta'(x, y)$ が等しければ 1 を、それ以外ならば 0 を返す。

最終的に、Low-Level 幾何学特徴は、隣接フレーム間の輝度勾配ヒストグラム $h_k(x, y)$ の差分により求まる。ここで、時刻 t における輝度勾配強度ヒストグラムを $h_k(x, y, t)$ とおくと、輝度勾配ヒストグラム差分 $S_k(x, y)$ は、式(9)により得られる。

$$S_k(x, y) = h_k(x, y, t) - h_k(x, y, t-1) \quad (9)$$

3.2 Mid-Level 幾何学特徴

Mid-Level 幾何学特徴は、セルの座標位置、時刻の 3 次元ベクトルで構成されたマスクパターンに、輝度勾配方向の情報を加えた 4 次元空間上における勾配強度の自己相関を算出することで得られる。図 4 に特徴抽出の概要を示す。セルの座標位置は XY 平面で定義される。時系列情報は t 軸で定義される。更に、輝度勾配方向は、セル毎のビン数により定義され、これらの 4 次元ベクトルを用いて任意の輝度勾配強度が表される。

ここで、マスクパターンの構成について説明する。マスクパターンは $N \times N \times N$ セルで定義されたマスクブロック内の 3 次元ベクトル (x, y, t) から得られるブロックの組み合わせパターンである。

例として、次数 2 のマスクパターンを考える。ここで用いる次数とは CHLAC 特徴の次数同様に着目する変位の数であり、着目変位の数が基準点を除いて 2 点あることを示す。

CHLAC では着目する変位の位置(以後、変位点)は、マスクブロックの全てのセルに設定される可能性があるが、提案手法では変位点の位置は各フレームで 1 つに限定する。更に基準点が設定されたフレームには変位点を設定しない。つまり、計算対象となるセルは常にフレームに 1 つだけ存在することになる。これらの制約を用いることで、マスクパターンの組み合わせは、起点の置かれたフレームを除いた残りの前後 2 フレームから各一点ずつを抽出することになり、それぞれのフレームの 9 セルを組み




図5 次数 2 のマスクパターン組み合わせ

合わせてマスクパターンが作成される。つまり、次数 2 の場合、マスクブロック内には 81 ($=9 \times 9$) のマスクパターンが定義される。次数 2 のマスクパターン組み合わせ概要を図 5 に示す。

また、次数を N とした場合のマスクパターン数を式(10)に示す。

$$\text{マスクパターン数} = (W \times H \times C_1)^{(N-1)} \quad (10)$$

ただし、マスクパターンを構成するブロックサイズを $H \times W$ とする。

入力画像全体で抽出される特徴の総数は、セル領域サイズに分割した画像に対して、マスクブロックを 1 セルずつずらして走査したマスクブロック数となる。

1 画像に $H \times W$ 個のセルが存在する場合、1 画像あたり $(W-N+1) \times (H-N+1)$ 個のマスクブロックが得られる。更に角度方向を組み合わせると $(W-N+1) \times (H-N+1) \times K$ 個の特徴が得られる。ここで、セル位置 (x, y) を位置ベクトル r とし、輝度勾配差分 $S_k(x, y)$ を $f(r, k)$ と置くと、 N 次の自己相関特徴は(11)式により得られる。

$$X(a_1, \dots, a_N, k_1, \dots, k_N) = \int_{C \in I} f(r, k) f(r+a_1, k_1) \dots f(r+a_N, k_N) \prod_{i=1}^{N-1} \alpha \cdot G(k - k_{i+1}) dr \quad (11)$$

ただし、 a_n は変位ベクトル、 k 並びに k_n は勾配方向、 N は自己相関の次数、 α は係数、 $G(\cdot)$ はガウスカネル、そして C はマスクブロック数を表す。ガウスカネルを用いることで隣接する勾配方向の強度のみが重みづけされ、角度方向の異なる勾配で構成されるマスクパターンの影響が低減される。

このように、我々の提案する幾何学特徴は、事前に複雑なマスクパターンを定義する必要がないため、CHLAC よりも実装が容易におこなえる。

3.3 動作の識別

幾何学特徴の算出により得られた特徴量を用いて AdaBoost 識別器を作成し、起床行動の識別を行う。本研究では、マスクパターン数を弱識別器の次元数として用い、サンプルデータのマスクパターン毎の応答値から確率分布を生成し、識別器を構築する。AdaBoost の具体的なアルゴリズムを以下に示す。

1) 初期化: 全てのサンプルの重みを初期化する。

$$w_i^1 = 1/m (i=1, \dots, m)$$

i はサンプルのインデックス、 w_i^1 は、学習 1 回目に用いるサンプルの重み、 m はサンプル数を示す。

2) Do for $t=1, 2, \dots, T$

ここで、 T は学習ラウンドの回数を表す。

a) 学習器によりサンプルの重み分布 w_i^1 に応じて弱識別器 $h_t(x)$ を学習し仮説を得る。

$$h_t(x): x \rightarrow \{-1, +1\}$$

このとき実験データでは、各マスクパターンの応答値が各弱識別器として用いられる。

b) 学習サンプルに対する誤り率を計算する。

$$\varepsilon_t = \sum_{i=1}^N \omega_i^t [h_t(x_i) \neq y_i] \quad (12)$$

$$\beta_t = \varepsilon_t / (1 - \varepsilon_t), a_t = \frac{1}{2} \log(1 / \beta_t) \quad (13)$$

c) サンプルの重みを更新する。

$$\omega_i^{t+1} = \frac{\omega_i^t}{z_t} \begin{cases} e^{-a^t}, & \text{if } h_t(x_i) = y_i \\ e^{a^t}, & \text{if } h_t(x_i) \neq y_i \end{cases} \quad (14)$$

z_t は重み ω_i^t を正規化する係数である。

3) 式(15)より、最終仮説を得る。

$$H(x) = \text{sign} \left(\sum_{i=1}^T a_i h_i(x) \right) \quad (15)$$

4. コヒーレンス

特徴量を周波数領域にて解析すると、それぞれの周波数帯におけるパワースペクトルを得ることができる。しかし、パワースペクトルのみの解析では、各周波数帯における波野位相情報を失うことになる。周波数領域にて、パワースペクトルとその位相情報を含めた解析をおこなう手段としてコヒーレンスがある。コヒーレンスは各種信号における雑音検出や、レーザー光や電波の延滞時間の推定などに使われるだけでなく、パワースペクトルと位相情報の相関性を測定できることから、動作認証としても用いることができる[16]。

4.1 コヒーレンスの求め方

コヒーレンスは、二つの時系列信号 $m(t)$, $s(t)$ のクロススペクトルの二乗と、それぞれのパワースペクトルの商により算出される。パワースペクトルの算出を式(16)に示す。

$$C_{ms}(f) = \frac{|P_{ms}(f)|^2}{P_{mm}(f)P_{ss}(f)} \quad (16)$$

$$0 \leq C_{ms}(f) \leq 1 \quad (17)$$

$C_{ms}(f)$ は、周波数 f における、二つの時系列信号のコヒーレンス P_{mm} , P_{ss} は $m(t)$, $s(t)$ それぞれのパワースペクトル, P_{ms} は $m(t)$, $s(t)$ のクロススペクトルを表す。クロススペクトルとは、2 信号に含まれる共通のパワー成分関数である。二つの入力信号が同一のものであれば、全ての周波数帯においてコヒーレンスは 1 になる。逆に、二つの入力信号に全く相関がなく、信号が独立したものであれば、すべての周波数帯においてコヒーレンスは 0 になる。また、相関のない二つの信号で周波数成分が類似していたとしても、コヒーレンスの位相情報を含めた解析により二つの信号の相関が低いことを示す。

5. 実験 1

5.1 実験概要

実験では、異常行動の推定などに頻繁に用いられている CHLAC[15]を、行動推定アルゴリズムにおける従来の手法(Conventional Method)とし、我々の提案手法




図 6 Positive データサンプル



図 7 Negative データサンプル

(Proposal Method)との認識精度の比較実験をおこなう。比較方法は、各手法を用いて入力画像から起き上がり動作を推定し、双方の検出性能を比較する。入力画像にはベッド周辺の人物の動きを撮影した動画を用いる。

撮影は、ベッドの頭部側壁面 200[cm]の高さに画角 70 度のカメラを設置し、ベッド上の人物だけでなくベッド周辺の人物の動作も記録する。動画は 15[fps]で撮影されたものを使用し、自己相関の次数は 2 とする。更に、実験データの撮影上のノイズや画像センサデバイスのオートアイリスなど自動補正の影響を低減するために幾何学特徴は 8 フレームの移動平均で得られた結果を用いる。

実験は検出性能を極力維持した状態で処理速度を向上させるという観点からフレームレートを 3[fps], 学習回数 100 回に固定して、解像度を 320×240[pix], 160×120[pix], 80×60[pix], 40×30[pix]の 4 階調に変化させた場合の検出性能を測定した。

5.2 実験データ

実験データは、起き上がり動作を撮影した 31 データと、起き上がり以外の動作を撮影した 64 データの 2 種類を用いる。起き上がり動作のデータを Positive データ、起き上がり以外の動作を Negative データと定義する。Positive データのサンプルを図 6 に、Negative データのサンプルを図 7 に示す。起き上がり動作は、仰向け状態からの起き上がり、横を向いた状態からの起き上がりや手すりにつかまりながら起き上がる動作を用いる。一方、

起き上がり以外の動作は、椅子に座った状態からの立ち上がりや、歩行、前かがみの動作を用いる。

病院施設などで高齢者の起き上がり動作を観察した結果、施設高齢者が起き上がる際にかかる時間はおよそ 8 秒程度である。そこで、評価に用いる動画シーケンスのデータ長を 8 秒とした。

5.3 実験結果

4 分割交差検定によりエラー率を測定する。それぞれの検定において、データの 75%を学習データとして使用し、残りの 25%を評価データとして用いた。異なる学習データと評価データの組み合わせで、4 通りの試験を各パラメータの組み合わせに対して実施した。評価結果として画像サイズ毎の未検出率を図 8 に、画像サイズ毎の誤検出率を図 9 に示す。評価の結果、従来手法は画像サイズ 80×60[pix]の時に最も高い性能を示し、未検出率が 14.1[%]発生し、誤検出率が 35.5[%]発生した。提案手法は画像サイズ 80×60[pix]の時に最も高い性能を示し、未検出率が 4.7[%]発生し、誤検出率が 25.8[%]発生した。この結果から提案手法は従来手法を上回る行動推定の性能といえる。




図8 未検出率




図9 誤検出率

6. 実験2

提案手法により得られた自己相関特徴を周波数に変換し、変換により得られた周波数を用いて動作を推定する。実験1の評価結果と実行結果を比較することで、周波数変換による検出性能に対する効果を調査する。

実験は、2段階で効果を確認する。はじめに周波数変換による効果を調べるために、提案手法の自己相関特徴を周波数変換したものを AdaBoost 識別器にかけ、識別性能の変化を調査する。次に、コヒーレンスによる効果を調べるため、提案手法の自己相関特徴を周波数変換したものに対して、教師データとのコヒーレンスを用いて相関を取り、その応答値を用いて、動作の推定をおこなう。

実験2でも実験1と同様のパラメータを用いて評価を実施する。なお、この設定で得られた従来手法における検出性能は、未検出率 4.7[%]、誤検出率 25.8[%]である。

評価データは実験1と同じデータを使用し、データ数も Positive データ 31 シーケンス、Negative データ 64 シーケンスの合計 95 シーケンスを用いる。

6.1 AdaBoostによる識別

入力シーケンスから得られた自己相関特徴を周波数変換し、AdaBoost 識別器により識別した評価結果として、未検出率を図10、誤検出率を図11に示す。評価は、実験1と同じく4分割交差検定を用いて検出性能を集計した。

評価結果が示すとおり、AdaBoost を用いた実験では、抽出した自己相関特長をそのまま識別した場合と、自己相関特徴を周波数に変換した場合を比較した結果、最も高い性能を記録した解像度 80×60 ピクセルにおいて、未検出率 4.7[%]、誤検出率 19.4[%]と誤検出率が 6.4[%]改善した。

6.2 コヒーレンスを用いた識別

コヒーレンスを用いた識別は、正例と入力データとのスペクトル比較をおこなうために、起き上がり動作に対する正例が必要となる。本実験では、評価データの起き上がりデータ1件を選択し、そのデータを正例として用いた。起き上がりの正例を図12に示す。




図10 周波数を用いた未検出率




図11 周波数を用いた誤検出率

検出性能の評価は、評価データ 94 シーケンスに対して識別を実行し、出力されたコヒーレンスの応答値に対して閾値を用いて起き上がり動作か非起き上がり動作かを判定した。閾値の設定で未検出率と誤検出率が左右されるため、閾値を網羅的に変化させ評価を実施した。評価の結果を Detection Error Tradeoff(DET) [18]を用いて図13に示す。DET とは、横軸に誤識別率、縦軸に未識別率を表したものである。識別器の閾値を変化させることにより、誤識別率に対する未識別率の比較をおこなえる。

実験の結果、内部閾値 0.8 の設定において未検出率 22.4[%]、誤検出率 53.3[%]となり、実験1で最も性能の低い結果を示した、従来手法の 320×240[pix]における未検出率 17.2[%]、誤検出率 54.8[%]より低下した。

7. 考察

従来手法と比較して提案手法の性能が向上した要因について考察する。

効果が大きいと考えられる要因の一つに、幾何学特徴の形状表現能力が考えられる。CHLAC は画像の局所領域の濃淡変化の組み合わせで表現される特徴量であるのに対して、提案手法は局所領域の濃淡変化から輝度勾配を抽出し、その輝度勾配を用いてエッジを表現した。このため提案手法は単なる動きの変化だけでなく物体の形状を表現した特徴であると言える。

物体の形状表現能力が向上することにより、識別性能が向上する例として、視覚的に理解しやすい歩行シーンの例を用いて説明する。図14は画面左から右へ歩行する人物と、更にその奥で別の人物が画面左方向へ歩行して、両者が交差するシーンである。このシーンから従来手法、提案手法それぞれを用いて Low-Level の幾何学特徴量を抽出した結果が図15の(a), (b)である。

ここで、人物が交差する部分に着目し、その領域を拡大したのが図15の(c)(d)である。丸で囲まれた領域内の横方向の特徴は後ろの人物の特徴であり、縦方向の特徴は手前の人物の特徴である。

この画像から CHLAC 特徴を抽出した場合、手前の人物の特徴と奥の人物の特徴とは同一の特徴として処理される。しかし、提案手法を用いた場合、式(11)の中で示した




図12 正例シーケンス




図13 DET



(a) N[s] (b) N+1[s]

図14 歩行シーン





図15 歩行シーンの特徴抽出結果

ガウスカーネルにより、手前の人物の特徴と奥の人物の特徴は位相差が考慮され、お互いの影響が低減される。我々は、性能向上の要因の一つとして、この特徴の表現能力の差があると考えた。

また、コヒーレンスを用いた識別手法については、AdaBoost 識別器程の効果を得られないが、周波数成分をAdaBoostで識別する事で検出性能が向上した。

8. むすび

本論文では、起床動作の検出を検討した。独自データセットを用いた評価の結果、従来手法は未検出率が14.1[%]、誤検出率が35.5[%]発生した。それに対して、提案手法は未検出率が4.7[%]、誤検出率が25.8[%]発生した。我々の提案する輝度勾配差分を用いた自己相関特徴はCHLAC特徴の行動認識性能を上回ることを確認した。また、コヒーレンスを用いた識別器の検討では検出性能は向上しないが、特徴量を周波数変換することにより、従来手法と比べて未検出率が9.4[%]、誤検出率が16.1[%]改善することを確認した。

今後、周波数を用いた識別について更なる検討を行う。

文献

- [1] L. Z. Rubenstein, K. R. Josephson, and S. R. Alan, "Falls in the nursing home," *Ann Intern Med*, vol. 121, no. 6, pp.442-451, 1994.
- [2] 須貝 佑一, 小林 奈美, "施設における痴呆高齢者の転倒・転落事故の発生状況と対策," *看護学会誌*, 68(1), pp.10-18, 2004
- [3] Lv. Qingcong, "A poselet-based approach for fall detection," *IT in Medicine and Education 2011*, vol. 2, pp. 209-212, 2011.
- [4] C. Rougier, J. Meunier, A. Saint-Arnaud, and J. Rousseau, "Monocular 3D head tracking to detect falls of elderly people," *28th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 6384-6387, 2006.
- [5] J. S. Brown, E. Vittinghoff, J. F. Wyman, K. L. Stone, M. C. Nevitt, K. E. Ensrud, D. Grady, "Urinary incontinence: does it increase risk for falls and fractures? Study of Osteoporotic Fractures Research Group," *Journal of the American Geriatrics Society*, vol. 48, no. 7, pp.721-725, 2000.
- [6] Bingbing Ni, "RGBD-camera based get-up event detection for hospital fall prevention," *ICASSP 2012*, pp.1405-1408, 2012.
- [7] A. Fitzgibbon, M. Cook, T. Sharp, M. Finocchio, R. More, A. Kipman, A. Blake, "Real-Time human pose recognition in parts from signal depth images," *CVPR 2011*, pp. 1297-1304, 2011.
- [8] V. Megavannan, B. Agarwal, R. V. Babu, "Human action recognition using depth maps," *SPCOM 2012*, pp. 1-5, 2012.
- [9] R. Girshick, J. Shotton, P. Kohli, A. Criminisi, A. Fitzgibbon, "Efficient regression of general activity human poses from depth images," *ICCV 2011*, pp. 415-422, 2011.
- [10] C. Rougier, E. Auvinet, J. Rousseau, M. Mignotte and J. Meunier, "Fall Detection from Depth Map Video Sequences," in *International Conference On Smart Homes and Health Telematics*, pp. 121-128, 2011.
- [11] I. C. Albitar, P. Graebler, C. Doignon, "Robust structured-light coding for 3D reconstruction computer vision," *ICCV 2007*, pp. 1-6, 2007.
- [12] S. T. O'Keefe and J. N. Lavan, "Clinical significance of delirium subtypes in older people," *Oxford Journals Medicine Age and ageing*, No.28, vol. 2, pp. 115-119, 1992
- [13] J. T. Walker, S. P. Lofton, L. Haynie, T. Martin, "The Home Health Nurses' Role in Geriatric Assessment of Three Dimensions: DEPRESSION, DELIRIUM, AND DEMENTIA," *Home Healthcare Nurse*, Vol. 24, no.9, pp. 572-578, 2006.
- [14] Watanuki Hayami, Kano Taro, Kameyama Kinuyo, Tsukui Yukari, Moroda Ryoko Nakano Yoshiko, Kanda Kiyoko, "The Prevalence and Cause of Delirium After Operation of Aged Surgical Patient in Urology Department," *Annals of Gunma University School of Health Sciences*, Vol. 23, pp. 109-116, 2002.
- [15] N. Otsu, "Towards Flexible and Intelligent Vision Systems -From Thresholding to CHLAC-, " *MVA2005*, pp.430-439, 2005.
- [16] 行方エリキ, 石原進, 水野忠則, "携帯端末の動きによる個人認証:コヒーレンスに基づく評価(セキュリティ・管理)." *情報処理学会研究報告*, Vol.28, pp.37-44, 2005.
- [17] 鈴木一史, "3次元高次局所自己相関特徴マスクを用いたソリッドテキストチャの分類," *情報処理学会論文誌*, Vol.48, No.3, pp.1524-1531, 2007.
- [18] 鷺見和彦, 関真規人, 波部 奇, "物体検出・背景と検出対象のモデリング -", *情報処理学会研究会 研究報告 (CVIM2005)*, Vol.2005, No.88, pp. 79-98, 2005.