Vol.2017-ASD-10 No.3
2017/11/18

マイクロ波ドップラセンサを活用した転倒検知

柴和彰[†1]　鏑木崇史[†1]　栗原陽介[†1]

概要：高齢社会になる中，高齢者の転倒や転倒による後遺症は治療が困難で大きな問題となっている．独居高齢者の転倒は特に危険である．高齢者が転倒した場合，起き上がるには介護者のサポートが必要になる．また意識を失う可能性も考えられる為，独居高齢者が転倒すると低体温症や脱水症状になり死に繋がる恐れもある．従って転倒の早期発見が要求される．そこで本研究ではマイクロ波ドップラに基づいた転倒検知システムを提案する．

キーワード：転倒検知，マイクロ波ドップラセンサ，周波数分布，隠れマルコフモデル

1. 序章

高齢化は国際的に進行しており，2030 年には 65 歳以上の高齢者の人口は 14 億人に到達すると推定されている[1]．そのような高齢社会になる中，高齢者の転倒や転倒による後遺症は治療が困難で大きな問題となっている．高齢者の転倒による入院の原因としては股関節骨折や外傷性脳損傷，上肢の損傷等が挙げられる[2]．そして転倒の発生件数は高齢化に伴って増加しており，65 歳から 70 歳までの約 30%，70 歳以上の約 40%が年間で転倒を経験している[2],[3]．独居高齢者の転倒は特に危険である．高齢者が転倒した場合，起き上がるには介護者のサポートが必要になる．また意識を失う可能性も考えられる為，独居高齢者が転倒すると低体温症や脱水症状になり死に繋がる恐れもある[4]-[7]．従って転倒の早期発見が要求される．

そのような状況下でセンサを活用し，自動的に転倒検知するシステムの開発が多く試みられている．使用するセンサは大きく分けて拘束型と無拘束型の２種類になる．拘束型センサとしては加速度計[8]-[16]や携帯カメラ[17]等が挙げられる．更に精度向上の為，加速度計と角度センサ[18]-[24]や磁力計[22],[23]，大気圧センサ[23]-[26]，筋電計[27]，電子コンパス[28]そして携帯カメラ[29]等を併用するシステムも考えられている．しかし拘束型センサを使用する場合，高齢者が終日それらを身に着けていなければならない．また定期的なセンサの充電が必要となり，それらが高齢者の負担となってしまう可能性がある．

無拘束なセンサとして，カメラ[30]-[39]やマイクロフォン[40]-[42]，ドップラセンサを活用し転倒検出を行った研究がある．[44]-[52]ではカメラから得られたデータを元に画像信号処理技術を用いて転倒検出を可能としている．しかし画像を用いることでプライバシーの問題が発生し浴室やトイレに設置できない可能性が考えられる．またマイクロフォンを使用する場合は音を計測することで転倒を検出しているが，周囲の雑音が入ることにより誤検出することが考えられる．これらの問題を考慮した上で本研究ではドップラセンサに焦点を当てた．ドップラセンサは対象者の速度を無拘束に捉えられ，プライバシーの問題も発生しない．以上を踏まえてドップラセンサが高精度な転倒の早期発見に適していると考えられる．以上を踏まえてドップラセンサが高精度な転倒の早期発見に適していると考えられる．

そしてドップラセンサを用いた転倒検出の信号処理の手順として，様々な周波数分析や判別手法が用いられている．実際に使われている周波数分析方法は短時間高速フーリエ変換（STFT）[44]-[47]やケプストラム分析[44]-[46]，ウェーブレット変換（WT）[48],[50]等が挙げられる．また判別方法としては Support Vector Machine(SVM) [44]-[46],[51],[52]や k-nearest neighbor(kNN) [44],[45],[50]，マハラノビス距離等が挙げられる．更に転倒のダイナミクスを考慮した方法として Hidden Markov Model（HMM）[47]が挙げられる．

本研究ではマイクロ波ドップラセンサを使用し隠れマルコフモデルを活用し，任意の種類の転倒及び非転倒のダイナミクスを考慮したモデルを構築し，転倒検出を行う．

2. 提案手法

本章では我々が考案した転倒を検知する為の提案手法を示す．転倒時は他の日常生活の動作と比較して鉛直下向き方向に高い速度がかかることが考えられる．マイクロ波ドップラセンサを用いてその速度を取得する．Fig.1 は本研究の提案手法の概要図である．マイクロ波ドップラセンサは天井に設置することで下向き方向にマイクロ波を照射し，その方向の速度に対応した時系列上の信号を出力する．また本研究では連続波（CW）ドップラモードのマイクロ波ドップラセンサを用いる．

本研究の提案手法は大きく 2 つに分かれる．転倒・非転倒モデルを構築する為の学習パート(2.1 節)と構築されたモデルを用いて未知のデータが転倒時のものか推定する推定パート(2.2 節)である．ここで $k(=1,2,3,\cdots,K)$はサンプリング間隔 Δt で A/D 変換された離散時間ステップ数，K はデ

†1 青山学院大学　理工学部　経営システム工学科

ⓒ 2017 Information Processing Society of Japan

ータ点数, $I(k)$はマイクロ波ドップラセンサから得られた離散信号を示す.

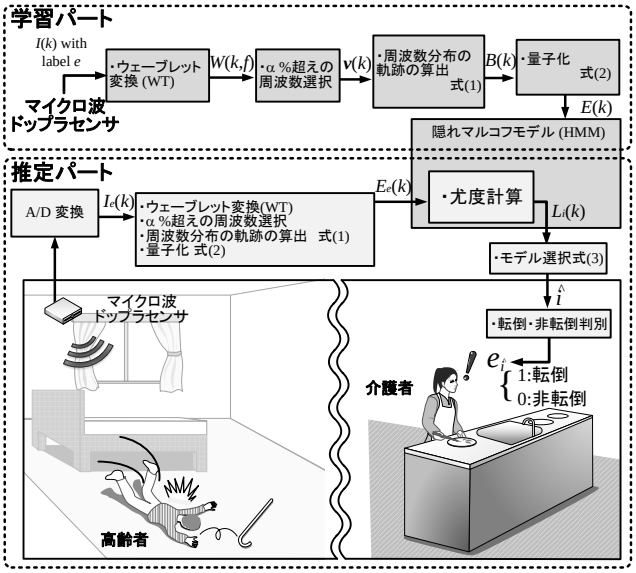

図 1　本研究の提案手法の概要図．マイクロ波ドップラセンサは天井に設置されデータは全て A/D 変換し信号処理を行う．

2.1 転倒モデルの作成

転倒モデルを構築する為に用いるデータ $I(k)$が示す事象を $e \in (0,1)$と定義する．0 が非転倒，1 が転倒を示す．

$I(k)$に対して，ウェーブレット変換（WT）を行うことで時間-周波数データ $W(k,f)$が得られる. f は離散周波数, $W(k,f)$は $I(k)$の各時間 k ごとの周波数特性を示す．ウェーブレット変換を行う際のマザーウェーブレットはメイヤー，スケールは f_{low}Hz から Δf Hz 刻みで f_{high} Hz までに相応するように設定する．対象の速度に対応し，周波数特性 $W(k,f)$に特徴が現れる．仮に高齢者が転倒した場合，それに相応する周波数が強い強度を持つと仮定できる．また転倒時，センサが照射するマイクロ波に対して様々な角度の速度が検出されることを考えると 1 つの周波数だけでなく複数の周波数が特徴を持つと考えられる．そこで本研究では各時刻の周波数の分布を速度に対応する特徴として焦点を当てる．

各時間点数 k における周波数分布の軌跡(Frequency Distribution Trajectory, FDT)を 1 次元の時系列データ $B(k)$として $W(k,f)$から以下の手順で算出する．周波数点数を F とすると 2 次元データ $W(k,f)$のデータ点数の合計は F 及び K と表される. $W(k,f)$の全データを降順に並べ, 上位 α%($\alpha/100 \times F \times K$)の地点のデータを T として選択する．そして各時刻で T を上回る強度を持つ周波数を選択し，それらを $\boldsymbol{v}(\boldsymbol{k})$とする．$\boldsymbol{v}(\boldsymbol{k})$がスカラーである場合は，その値が $B(k)$となるが，$\boldsymbol{v}(\boldsymbol{k})$は空集合である可能性や複数の周波数を持つベクトルである可能性がある. 仮に $\boldsymbol{v}(\boldsymbol{k})$が空集合であった場合, $B(k)$の値は 0 となる．$\boldsymbol{v}(\boldsymbol{k})$が複数個の値を持つ(ベクトルである)場合は, 式(1)のように $\boldsymbol{v}(\boldsymbol{k})$の最も大きな値を $B(k)$として選択する.

$$B(k) = \max\{\mathbf{v}(k)\} \tag{1}$$

転倒時の $B(k)$の確率分布をモデル化する為に $B(k)$の値を特定の量子化数 n で量子化しファクタ D でダウンサンプリングを行う．そのデータを $E(k)$とする.

$$E(k) = \begin{cases} 1: & f_{low} < B(k) \le \dfrac{f_{high}}{n} \\ 2: & \dfrac{f_{high}}{n} < B(k) \le 2\dfrac{f_{high}}{n} \\ \vdots & \\ n: & (n-1)\dfrac{f_{high}}{n} < B(k) \le f_{high} \end{cases} \tag{2}$$

そして各状態 e が定義されたデータを HMM を確立する為の学習データとして集める. $E_i(k)$ (i=1,2,⋯,N+M)の事象を e_i とする.

本研究では Ergodic HMM を用いて状態 1,⋯,s が全遷移することを前提に置き，$E(k)$とそれぞれの動作のモデル化を行う．HMM のパラメータとしては状態遷移行列，出力確率及び初期状態確率が挙がり，それらを Baum-welch アルゴリズムにより学習させる．それにより任意の N 種類の転倒動作モデルと M 種類の非転倒動作モデルが確立する.

2.2 転倒検知

(2.1)節で得られた転倒モデルを用いて転倒検知を行う．2.1 節で用いたデータを活用し, モデルと比較し状態を決定する．状態 e_{new} が未知のデータ $I_{new}(k)$を 2.1 節と同様な手順で量子化データ $E_{new}(k)$まで変換する．そして各行動モデルとの尤度 L_i を算出し, 式(3)のように最も尤度が高く示したモデルと同じ動作をしていると推定する．そのモデルの事象 $e_{\hat{i}}$ が 1 を示していれば転倒動作，0 を示していれば非転倒動作となる.

$$\hat{i} = \arg\max_i \{L_1, L_2, \cdots L_i, \cdots, L_{N+M}\} \tag{3}$$

3. 実験

2 章で示した提案手法の妥当性を評価する為の実験を行う.

3.1 実験システム

Fig.2 に本実験の計測システムを示す. センシングデバイスとしては搬送波周波数が 24.125±0.125GHz のマイクロ波ドップラセンサ（InnoSenT:IPS154）を使用する．そして IPS154 は一般的な屋内での天井の高さを想定し 2.5m 上方に下向きへマイクロ波を照射できるように設置する．また IPS154 の仕様からマイクロ波を床まで照射できる範囲がデバイスを中心に半径 1.5m 以内となるので，その範囲を

実験エリアとして計測を行う．

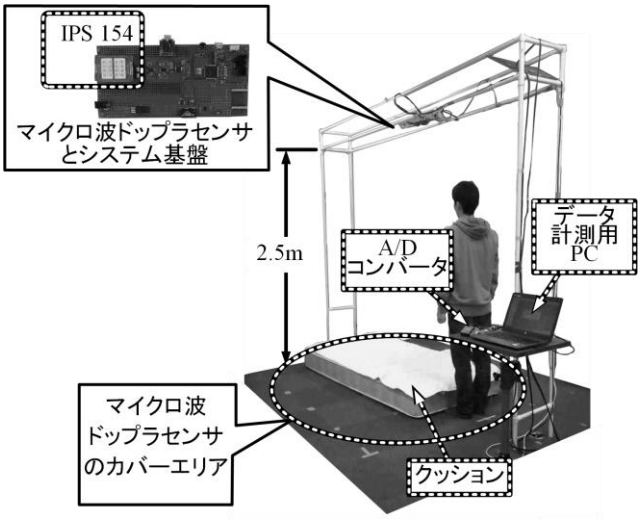

Fig.2　本実験のシステム．転倒を計測する際にはクッションが用意される．

IPS154 からはアナログ信号 $I(t)$が出力され，A/D コンバータ（CONTEC Co., Ltd.: AI-AIO-160802AY-USB）を用いてデジタル信号 $I(k)$へ 16 bit の分解能で変換する．そしてそれをデータ収集アプリケーション C-LOGGER を使用して csv ファイルとして PC 上で取得する．データは全てサンプリング間隔 Δt が 2.5×10^{-4} [s]，計測時間を 10[s]と設定し計測を行う．

3.2 実験条件

本実験を行うにあたり，20 名のインフォームドに同意した 20 歳から 24 歳の被験者に協力を頂いた．計測するデータとしては転倒データと非転倒データの 2 種類が挙げられる．

転倒データとしては躓いて転倒する動作(A1)，滑って転倒する動作(A2)そして気絶して転倒する動作(A3)をそれぞれの被験者ごとに 8 回分計測する．つまり転倒データは 1 人の被験者あたり 24 回分計測される．

非転倒データとしては歩行(B1)，ものを拾う動作(B2)，座る動作(B3)そして立つ動作(B4)の 4 種類をそれぞれの被験者ごとに 6 回分計測する．非転倒データも 1 人の被験者あたり 24 回分計測される．

合計して 1 人の被験者で 48 データ，20 人で 960 データ(転倒:480 データ，非転倒:480 データ)が計測される．

3.3 評価方法

計測データの動作推定を行う．計測した全ての転倒データ $I(k)$には事象ラベルとして 1 が付けられ，全ての非転倒データ $I(k)$に対しては 0 が付けられる．ここで全ての実験データを学習データとテストデータに分割する．次にウェーブレット変換を行い周波数特性を算出する．転倒時の人間の速度は 5m/s を超える為[50]，6m/s までの速度に対応する周波数特性を検証することとする．ここで f_d をドップラ周波数，f_m をマイクロ波の搬送波，c を光速，v を対象者の速度，θ をマイクロ波と対象者のなす角度（θ =0 と定義）とすると，

$$f_d = \frac{f_m}{c} v \cos\theta \tag{4}$$

と表すことができる．式(4)より，速度が 6m/s の際，約 960Hz の周波数に特性が反映される．そこでそれぞれのデータにマザーウェーブレットをメイヤーとし，20Hz（$=f_{low}$）から 20Hz($=\Delta f$)刻みで 960Hz($=f_{high}$)までの周波数に対応するようにウェーブレット変換を行い，$W(k,f)$を取得する．そして，α =5%と設定 $\boldsymbol{v(k)}$を算出し，計 960 個の $B(k)$を獲得する．

そしてダウンサンプリングのファクタを D=10 で設定し，異なる量子化数 n と状態数 s との組合せで推定結果の違いを検証する．量子化数 n としては 3,4,5,6，状態数 s としては 3,4,5,6,7 の 5 種類の 4 種類をそれぞれ組合せ，計 20 通り組合せの評価を行う．

本研究では評価方法として被験者ごとの交差検定を行う．従って 19 人分のデータ(転倒データ・非転倒データ両者とも 456 データ)を学習として(A1)，(A2)，(A3)，(B1)，(B2)，(B3)，(B4)を示す 7 つ(N=3，M=4)の HMM を構築する．そして 1 人分のデータ（転倒データ・非転倒データ両者とも 24 データ）がテストデータとして各々7 つの HMM と尤度 L_i を算出し比較することで，(A1)-(A3)，及び(B1)-(B4)のいずれかと推定される．(A1)-(A3) と推定された場合は転倒（e_{new}=1），(B1)-(B4) と推定された場合は非転倒（e_{new} =0）と推定される．

3.3.1 評価 1－精度の評価

推定結果としては True positive(TP)，False Positive(FP)，True Negative(TN)，False Negative(FN)の 4 種類が考えられる．TP は転倒を正しく推定できた場合，FP は非転倒を転倒と誤って判別した場合，TN は非転倒を正しく推定できた場合，そして FN は転倒を非転倒と誤って推定した場合である．この 4 種類の結果の数をカウントし，それを基に正答率(Accuracy)，陽性的中率(PPV, Positive Prediction Value)そして陰性的中率(Negative Prediction Value)の 3 種類の指標を計算して評価を行う．

$$\text{Accuracy} = \frac{(TP+TN)}{(TP+FP+FN+TN)} \tag{5}$$

$$PPV = \frac{TP}{(TP+FP)} \tag{6}$$

$$NPV = \frac{TN}{(TN+FN)} \tag{7}$$

4. 実験結果

4.1 4.1 転倒・非転倒データの一例

Fig.3 は躓いて転倒（A1）する動作を計測したデータである．Fig.3 の(a)はデバイスからの時系列データ $I(k)$，(b)はウェーブレット変換を行った周波数特性データ $W(k,f)$，(c)は周波数の分布 $B(k)$，そして(d)は(c)が n=5 で量子化されたデータ $E(k)$である．

この計測の際，被験者は計測開始(0 秒)から 3 秒までの間，静かにと歩行し，3 秒から 6 秒までの間に転倒し，6 秒から計測終了(10 秒)までの間，床に横たわっていた．最初の歩行している時間は Fig.3(a)に示されるように時系列データ $I(k)$に大きな変化は見られず周波数分布 $B(k)$も低い周波数が示されている．しかし被験者が転倒すると $I(k)$のデータの変化が大きくなり，$B(k)$も大きく変化し 4[sec]付近で最も高い周波数を示す．そして転倒し終え，床に寝そべっている状態になると $I(k)$の変化が極めて小さく $B(k)$も非常に低い周波数を示す．以上を踏まえて周波数分布 $B(k)$は転倒時に非常に特徴的な変化を示すことが分かる．

(B1)を見ると歩行している際は $I(k)$の値は各時間で均等に変化しているが，$B(k)$は全体的に低い周波数を示している．これに対して，(B2)-(B4)の $I(k)$は各動作時の変化が非常に大きく転倒データ(A1)-(A3)の $I(k)$の形に近い．しかし $B(k)$をみると(A1)-(A3)と比較して高い周波数は示されていない．

4.2 4.2 解析結果

TABLE. I は各組合せの正答率，PPV，NPV の平均±標準偏差が示されている．最も高い正答率を示したのは n=5，s=5 で 0.95±0.06 となり，最も低い組合せが n=6，s=6 で 0.73±0.14 となる．全ての組合せをみると n=4 または n=5 の場合が n=3，n=6 と比較して正答率が高くなっている．また最も高い陽性的中率を示した組合せは n=4, s=3 で 0.95±0.11 となり，最も低い陽性的中率を示した組合せは n=6，s=6 で 0.69±0.15 となった．陽性的中率も正答率と同様に n=5 または n=5 の場合が n=3，n=6 と比較して結果が良くなる．そして高い陽性的中率を示した組合せは n=5，s=4 で 0.99±0.03 となり，最も低い陽性的中率を示した組合せは n=6，s=4 で 0.94±0.13 となった．陰性的中率は全ての組合せが平均で 0.9 以上となり，非常に高精度である．

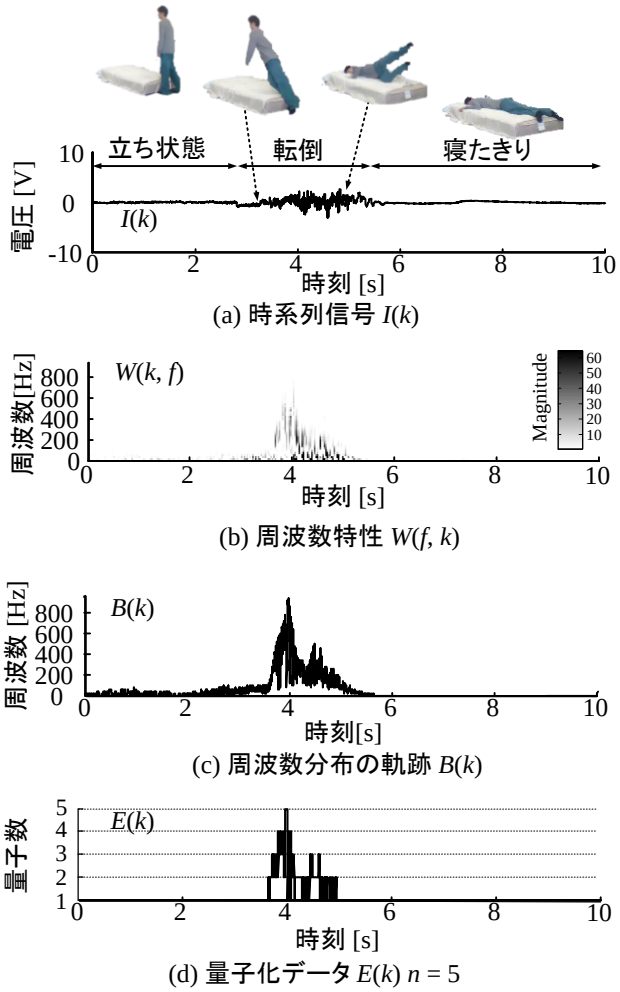

Fig.3 転倒データの一例．(a)が時系列データ $I(k)$，(b)がウェーブレット変換直後の時間 - 周波数データ $W(k,f)$，(c)が周波数分布 $B(k)$，(d)が(c)を n=5 で量子化したデータ $E(k)$.

全ての動作，(A1)-(A3)と(B1)-(B4)を計測したデータを Fig.4 及び Fig,5 に示す．(A1)-(A3)はいずれも転倒時，周波数分布 $B(k)$に 500Hz を超える非常に高い周波数が発生する．$B(k)$ の転倒中の変化を見ると，(A1)と(A3)は大きな変化は 1 回のみ発生するのに対して，(A2)は 2 回見られる．これは転倒中にバランスを取る為に体を多きく動かした結果だと考えられる．

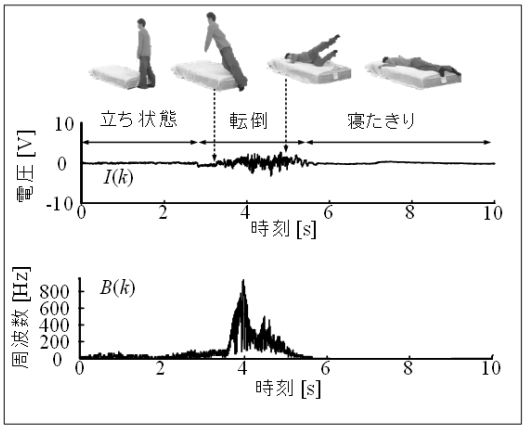

(A1) 躓いて転倒する動作

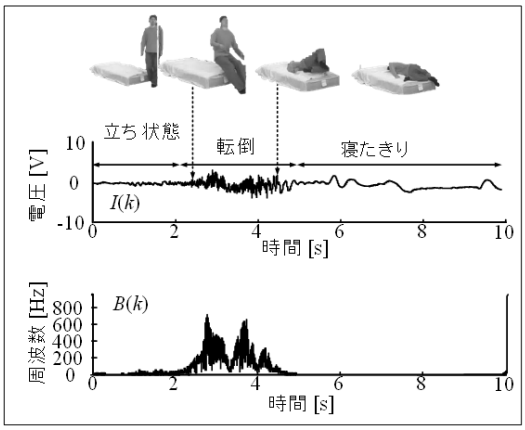

(A2) 滑って転倒する動作

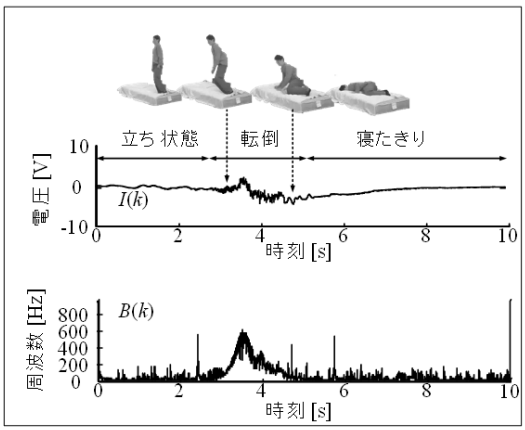

(A3) 気絶して転倒する動作

Fig.4　転倒動作(A1)-(A3)のデータ例

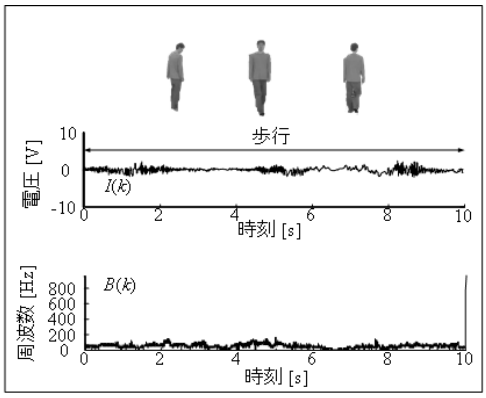

(B1) 歩行動作

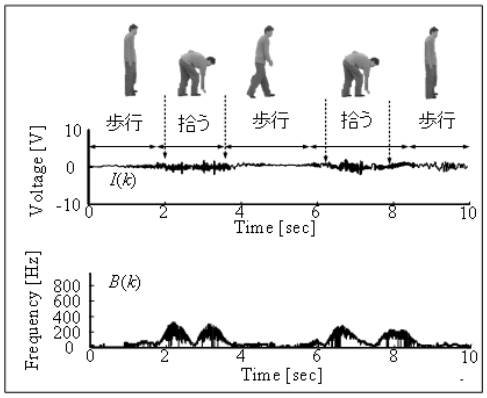

(B2) 物を拾う動作

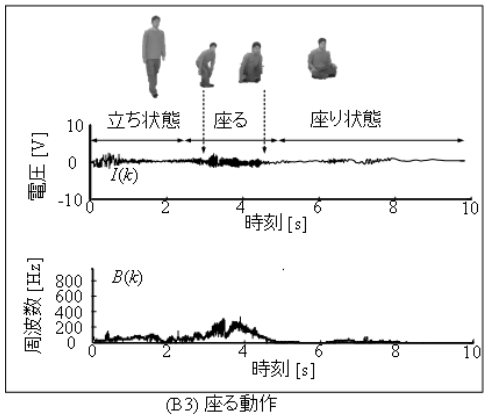

(B3) 座る動作

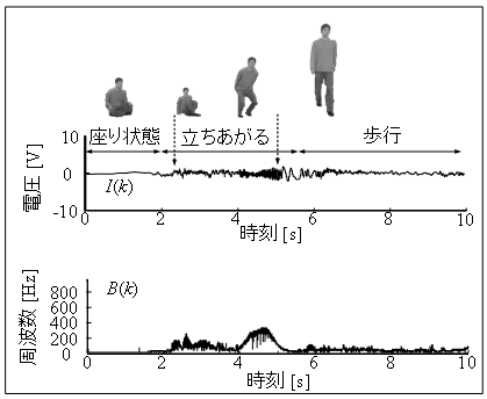

(B4) 立ちあがる動作

Fig.5　非転倒データ(B1)-(B4)のデータ例

ⓒ 2017 Information Processing Society of Japan

表 1

各組合せの正答率，陽性的中率，陰性的中率(平均±標準偏差)

			n: 量子化数			
			3	4	5	6
s: HMMの状態数	Accuracy	3	0.85±0.11	0.93±0.09	0.93±0.08	0.86±0.13
		4	0.84±0.11	0.92±0.09	0.95±0.07	0.82±0.16
		5	0.84±0.10	0.93±0.08	0.95±0.06	0.82±0.15
		6	0.84±0.10	0.93±0.07	0.94±0.07	0.73±0.14
		7	0.84±0.10	0.94±0.06	0.93±0.07	0.79±0.15
	PPV	3	0.80±0.15	0.95±0.11	0.91±0.10	0.83±0.17
		4	0.79±0.14	0.93±0.11	0.93±0.10	0.84±0.19
		5	0.79±0.14	0.93±0.11	0.94±0.09	0.79±0.19
		6	0.80±0.14	0.93±0.08	0.92±0.09	0.69±0.15
		7	0.79±0.14	0.92±0.10	0.90±0.10	0.76±0.18
	NPV	3	0.98±0.05	0.95±0.08	0.97±0.06	0.98±0.04
		4	0.98±0.06	0.95±0.09	0.99±0.03	0.94±0.13
		5	0.98±0.06	0.96±0.07	0.97±0.06	0.98±0.05
		6	0.99±0.05	0.95±0.08	0.98±0.06	0.98±0.06
		7	0.98±0.04	0.98±0.05	0.98±0.05	0.97±0.06

5. 考察

TABLE.II の上図は n=5，s=5 で HMM を行い，交差検定で評価を行った際の TP，FP，FN，TN の結果である．結果は TP=474，FP=6，TN=446，FN=34 となった．TP と TN の値が非常に大きく正答率や陽性的中率，陰性的中率が非常に高くなる．また(A1)-(A3)のデータ $I(k)$や周波数分布 $B(k)$を見ると大きな違いは見えない．同様に非転倒(B1)-(B4)を見ると特に(B2)-(B4)が似通っている．以上を踏まえると各動作の推定は非常に難しいように考えられる．

6. むすび

本研究では，マイクロ波ドップラセンサを用いて周波数の分布を算出し，HMM を活用することで転倒のダイナミクスを考慮に入れたモデルを構築し，転倒を検知できるシステムを開発した．そのシステムを評価する為に被験者を 20 名設け, 実験としてそれぞれに 3 種類の転倒動作（躓き，滑り，気絶），4 種類の非転倒動作（歩行，物を拾う，座る，立つ）を行ってもらいデータを計測した．計測したデータを用いて交差検定による評価を行ったところ正答率が 0.95，陽性的中率が 0.94，陰性的中率が 0.97 となった．

今後の課題は動作の種類を増やすことや，実験環境を変えることが考えられる．またより高精度な転倒検出を行う為には転倒のモーションで状態を分割し，データ点数単位で Viterbi アルゴリズム等を使って推定を行う必要がある．

参考文献

[1] United Nations, Department of Economic and Social Affairs, Population Division (2015). World Population Ageing (ST/ESA/SER.A/390), p. 2, (2015) (references)

[2] World Health Organization Ageing and Life Course, Family and Community Health Unit, WHO Global Report on Falls Prevention in Older Age, Geneva, Switzerland, (2008)

[3] P. Kannus, M. Palvanen, S. Niemi, J. Parkkari, “Alarming Rise in the Number and Incidence of Fall-induced Cervical Spine Injuries among Older Adults,” Journal of Gerontology: Biological Sciences and Medical

ⓒ 2017 Information Processing Society of Japan

Sciences, vol. 62, no. 2, pp.180-183 (2007)

[4] Lifeline with Autoalert Option. [Online]. Available: http: //www.lifelinesys.com/content/lifeline-products/auto-alert, accessed Jul. 14, (2013)

[5] E. Dejaeger, S. Boonen, J. Coussement, and K. Milisen, “Recurrent falling, osteoporosis and sarcopenia, three major problems, an integrated approach,” J. Gerontol. Geriatr., vol. 40, no. 6, pp. 262–269, Dec. (2009)

[6] R. J. Gurley, N. Lum, M. Sande, B. Lo, and M. H. Katz, “Persons found in their homes helpless or dead,” N. Eng. J. Med., vol. 334, no. 26, pp. 1710–1716, (1996)

[7] D. Wild, U.S. Nayak, and B. Isaacs, “How Dangerous Are Falls in Old People at Home?” British Medical J. (Clinical Research Ed.), vol. 282, no. 6260, pp. 266–268 (1982)

[8] C. F. Lai, S.Y. Chang, H.C. Chao, and Y.M. Huang, “Detection of Cognitive Injured Body Region Using Multiple Triaxial Accelerometers for Elderly Falling,” IEEE Sensors Journal, pp. 763-770, vol.11, no.3 (2011)

[9] Y. Liu, S. J. Redmond, N. Wang, F. Blumenkron, M. R. Narayanan, and N. H. Lovell, "Spectral Analysis of Accelerometry Signals from a Directed-Routine for Falls-Risk Estimation," IEEE Transactions on Biomedical Engineering, vol.58, no.8, pp.2308-2315 (2011)

[10] O. Aziz, and S.N. Robinovitch, "An Analysis of the Accuracy of Wearable Sensors for Classifying the Causes of Falls in Humans," IEEE Transactions on Neural Systems and Rehabilitation Engineering, vol.19, no.6, pp.670-676 (2011)

[11] D. N. Hernandez, L. M. Roa, J. R. Tosina, and M. A. E. Valderrama, “Personalization and Adaptation to the Medium and Context in a Fall Detection System,” IEEE Transactions on Information Technology in Biomedicine, vol.16, no.2, pp.264 - 271 (2012)

[12] Y. W. Bai, S. C. Wu, and C. L. Tsai, "Design and implementation of a fall monitor system by using a 3-axis accelerometer in a smart phone," IEEE Transactions on Consumer Electronics, vol.58, no.4, pp.1269-1275 (2012)

[13] W. C. Cheng, and D. M. Jhan, "Triaxial Accelerometer-Based Fall Detection Method Using a “Self-Constructing Cascade-AdaBoost-SVM Classifier," IEEE Journal of Biomedical and Health Informatics, vol.17, no.2, pp.411-419 (2013)

[14] L. Tong, Q. Song, Y. Ge, and M. Liu, "HMM-Based Human Fall Detection and Prediction Method Using Tri-Axial Accelerometer," IEEE Sensors Journal, vol.13, no.5, pp.1849-1856 (2013)

[15] J. Wang, Z. Zhang, B. Li, S. Lee, and R. S. Sherratt, “An Enhanced Fall Detection System for Elderly Person Monitoring Using Consumer Home Networks,” IEEE Transactions on Consumer Electronics, vol.60, no.1, pp.23 - 29 (2014)

[16] J. Yuan, K. K. Tan, T. H. Lee, and G. C. H. Koh, “Power-Efficient Interrupt-Driven Algorithms for Fall Detection and Classification of Activities of Daily Living,” IEEE Sensors Journal, vol.15, no.3, pp.1377 - 1387 (2015)

[17] K. Ozcan, A. K. Mahabalagiri, M. Casares, and S. Velipasalar, "Automatic Fall Detection and Activity Classification by a Wearable Embedded Smart Camera," IEEE Journal on Emerging and Selected Topics in Circuits and Systems, vol.3, no.2, pp.125-136 (2013)

[18] J. Liu, and T. E. Lockhart, "Development and Evaluation of a Prior-to Impact Fall Event Detection Algorithm," IEEE Transactions on Biomedical Engineering, vol.61, no.7, pp.2135-2140 (2014)

[19] H. E. Jian, and H. U. Chen, "A Portable Fall Detection and Alerting System Based on k-NN Algorithm and Remote Medicine," China Communications, vol.12, no.4, pp.23-31 (2015)

[20] J. K. Lee, S. N. Robinovitch, and E. J. Park, "Inertial Sensing-Based Pre-Impact Detection of Falls Involving Near-Fall Scenarios," IEEE Transactions on Neural Systems and Rehabilitation Engineering, vol.23, no.2, pp.258-266 (2015)

[21] B. Andò, S. Baglio, C. O. Lombardo, and V. Marletta, “A Multisensor Data-Fusion Approach for ADL and Fall Classification,” IEEE Transactions on Instrumentation and Measurement, vol.65, no.9, pp.1960-1967 (2016)

[22] S. W. Abeyruwan, D. Sarkar, F. Sikder, and U. Visser, “Semi-Automatic Extraction of Training Examples from Sensor Readings for Fall Detection and Posture Monitoring,” IEEE Sensors Journal, vol.16, no.13, pp.5406 - 5415 (2016)

[23] P. Pierleoni, A. Belli, L. Maurizi, L. Palma, L. Pernini, M. Paniccia, and S. Valenti, “A Wearable Fall Detector for Elderly People Based on AHRS and Barometric Sensor,” IEEE Sensors Journal, vol.16, no.17, pp.6733 - 6744 (2016)

[24] A. M. Sabatini, G. Ligorio, A. Mannini, V. Genovese, and L. Pinna, “Prior-to- and Post-Impact Fall Detection Using Inertial and Barometric Altimeter Measurements,” IEEE Transactions on Neural Systems and Rehabilitation Engineering, vol.24, no.7, pp.774 - 783 (2016)

[25] F. Bianchi, S. J. Redmond, M. R. Narayanan, S. Cerutti, and N. H. Lovell, "Barometric Pressure and Triaxial Accelerometry-Based Falls Event Detection," IEEE Transactions on Neural Systems and Rehabilitation Engineering, vol.18, no.6, pp.619-627 (2010)

[26] M. A. Brodie, K. Wang, K. Delbaere, M. Persiani, N. H. Lovell, S. J. Redmond, M. B. D. Rosario, and S. R. Lord, “New Methods to Monitor Stair Ascents Using a Wearable Pendant Device Reveal How Behavior, Fear, and Frailty Influence Falls in Octogenarians,” IEEE Transactions on Biomedical Engineering, vol.62, no.11, pp.2595 - 2601 (2015)

[27] J. Cheng, X. Chen, and M. Shen, “A Framework for Daily Activity Monitoring and Fall Detection Based on Surface Electromyography and Accelerometer Signals,” IEEE Journal of Biomedical and Health Informatics, vol.17, no.1, pp.38 - 45 (2013)

[28] L. J. Kau, and C. S. Chen, "A Smart Phone-Based Pocket Fall

ⓒ 2017 Information Processing Society of Japan

Accident Detection, Positioning, and Rescue System," IEEE Journal of Biomedical and Health Informatics, vol.19, no.1, pp.44-56 (2015)

[29] K. Ozcan, and S. Velipasalar, “Wearable Camera- and Accelerometer-Based Fall Detection on Portable Devices,” IEEE Embedded Systems Letters, vol.8, no.1, pp.6 - 9 (2016)

[30] N. Thome, S. Miguet, and S. Ambellouis, “A Real-time, Multiview Fall Detection System A LHMM-based Approach,” IEEE Trans.Circuits Syst. Video Technol., vol.18, no.11, pp.1522 - 1532, (2008)

[31] C. Rougier, J. Meunier, A. St-Arnaud, and J. Rousseau, "Robust Video Surveillance for Fall Detection Based on Human Shape Deformation," IEEE Transactions on Circuits and Systems for Video Technology, vol.21, no.5, pp.611-622 (2011)

[32] E. Auvinet, F. Multon, A. Saint-Arnaud, J. Rousseau, and J. Meunier, "Fall Detection with Multiple Cameras An Occlusion-Resistant Method Based on 3-D Silhouette Vertical Distribution," IEEE Transactions on Information Technology in Biomedicine, vol.15, no.2, pp.290-300 (2011)

[33] D. Brulin, Y. Benezeth, and E. Courtial, “Posture Recognition Based on Fuzzy Logic for Home Monitoring of the Elderly,” IEEE Trans.Inf.Technol. Biomed., vol.16, no.5, pp.974-982 (2012)

[34] M. Yu, A. Rhuma, S. M. Naqvi, L. Wang, and J. Chambers, "A Posture Recognition-Based Fall Detection System for Monitoring an Elderly Person in a Smart Home Environment," IEEE Transactions on Information Technology in Biomedicine, vol.16, no.6, pp.1274-1286 (2012)

[35] M. Yu, Y. Yu, A. Rhuma, S. M. R. Naqvi, L. Wang, and J. A. Chambers, “An Online One Class Support Vector Machine-Based Person-Specific Fall Detection System for Monitoring an Elderly Individual in a Room Environment,” IEEE Journal of Biomedical and Health Informatics, vol.17, no.6, pp.1002 - 1014 (2013)

[36] B. Mirmahboub, S. Samavi, N. Karimi, and S. Shirani, "Automatic Monocular System for Human Fall Detection Based on Variations in Silhouette Area," IEEE Transactions on Biomedical Engineering, vol.60, no.2, pp.427-436 (2013)

[37] X. Ma, H. Wang, B. Xue, M. Zhou, B. Ji, and Y. Li, “Depth-Based Human Fall Detection via Shape Features and Improved Extreme Learning Machine,” IEEE Journal of Biomedical and Health Informatics, vol.18, no.6, pp.1915 - 1922 (2014)

[38] E. E. Stone, and M. Skubic, "Fall Detection in Homes of Older Adults Using the Microsoft Kinect," IEEE Journal of Biomedical and Health Informatics, vol.19, no.1, pp.290-301 (2015)

[39] Z. P. Bian, J. Hou, L. P. Chau, and N. M. Thalmann, “Fall Detection Based on Body Part Tracking Using a Depth Camera,” IEEE Journal of Biomedical and Health Informatics, vol.19, no.2, pp.430 - 439 (2015)

[40] Y. Li, K. C. Ho, and M. Popescu, "A Microphone Array System for Automatic Fall Detection," IEEE Transactions on Biomedical Engineering, vol.59, no.5, pp.1291-1301 (2012)

[41] Y. Li, K. C. Ho, and M. Popescu, "Efficient Source Separation Algorithms for Acoustic Fall Detection Using a Microsoft Kinect," IEEE Transactions on Biomedical Engineering, vol.61, no.3, pp.745-755 (2014)

[42] M. Cheffena, "Fall Detection Using Smartphone Audio Features," IEEE Journal of Biomedical and Health Informatics, vol.20, no.4, pp.1073-1080 (2016)

[43] A. Ariani, S. J. Redmond, D. Chang, and N. H. Lovell, "Simulated Unobtrusive Falls Detection with Multiple Persons," IEEE Transactions on Biomedical Engineering, vol.59, no.11, pp.3185-3196 (2012)

[44] L. Liu, M. Popescu, M. Skubic, M. Rantz, T. Yardibi, and P. Cuddihy, “Automatic Fall Detection Based on Doppler Radar Motion,” in Proc.5th Int. Conf. Pervasive Computing Technologies for Healthcare, Dublin, Ireland, pp.222–225 (2011)

[45] L. Liu, M. Poposcu, M. Rantz, and M. Skubic, “Fall Detection Using Doppler Radar and Classifier Fusion,” in Proc. IEEE-EMBS Int. Conf. Biomed. Health Inform., pp.180–183 (2012)

[46] L. Liu, M. Poposcu, K. C. Ho, M. Skubic, and M. Rantz, “Doppler Radar Sensor Positioning in a Fall Detection System,” in Proc.34th Annu. Int. Conf. IEEE Eng. Med. Biol.Soc., pp.256–259 (2012)

[47] M. Wu, X. Dai, Y. D. Zhang, B. Davidson, J. Zhang, and M. G. Amin, “Fall Detection Based on Sequential Modeling of Radar Signal Time-frequency Features,” in Proc. IEEE Int. Conf. Healthcare Informatics, Philadelphia, PA, pp.169–174 (2013)

[48] A. Gadde, M. G. Amin, Y. D. Zhang, and F. Ahmad, “Fall Detection and Classification Based on Time-scale Radar Signal Characteristics,” in Proc. SPIE, Baltimore, MD, vol.9077, no.907712, pp.1–9 (2014)

[49] Q. Wu, Y. D. Zhang, W. Tao, and M. G. Amin, “Radar-based Fall Detection Based on Doppler Time-frequency Signatures for Assisted living,” IET Radar Sonar Navig., vol.9, no.2, pp.164 - 172, (2015)

[50] B. Y. Su, K. C. Ho, M. J. Rantz, and M. Skubic, "Doppler Radar Fall Activity Detection Using the Wavelet Transform," IEEE Transactions on Biomedical Engineering, vol.62, no.3, pp.865-875 (2015)

[51] C. Garripoli, M. Mercuri, P. Karsmakers, P. J. Soh, G. Crupi, G. A. E. Vandenbosch, C. Pace, P. Leroux, and D. Schreurs, "Embedded DSP-Based Telehealth Radar System for Remote In-Door Fall Detection," IEEE Journal of Biomedical and Health Informatics, vol.19, no.1, pp.92-101 (2015)

[52] M. G. Amin, Y. D. Zhang, F. Ahmad, and K. C. D. Ho, "Radar Signal Processing for Elderly Fall Detection The Future for In-home Monitoring", IEEE Signal Processing Magazine, vol.33, no.2, pp.71-80 (2016)

ⓒ 2017 Information Processing Society of Japan