

ドップラーセンサと深層学習による 実時間人物転倒検出手法の開発

今村 賢幸¹ 橋本 浩二¹ モシニャガ ワシリ¹

概要: 独居高齢者が居室内で転倒するのを速やかに検出しケアすることは、生命の安全・後遺症予防の観点から重要であるが、既存のシステムは、身体へのデバイス装着や監視カメラによる心理的負担等が問題となる。我々は、安価な 10GHz 帯ドップラーセンサを用いた、室内での人物の転倒を検出する手法の開発およびシステム全体の構築を目指している。ドップラーセンサで居室内の動きを常時モニタリングし、センサからの信号をスペクトログラム化した時系列データのなかから、人体の様々な動きのうちでも特に危険な「転倒」動作を識別する分類器を機械学習(LSTM)手法によって構成し、人物の転倒行動を検出するシステムを新たに構築した。本発表では提案手法、実験結果および今後の予定を述べる。

キーワード: ドップラーセンサ, LSTM, 人物の転倒検出

Development of Real-time Fall Detection Technique based on Doppler Sensor and Machine Learning

TAKAYUKI IMAMURA^{†1} KOJI HASHIMOTO^{†1} VASILY MOSHNYAGA^{†1}

Abstract: It is important from the viewpoint of safety of life and prevention of sequelae to quickly detect and care for falling elderly people living alone in the room. However, forcing a device to be attached to the body or psychological burden caused by a surveillance camera is a problem of the existing system. We aim to develop a method and system to detect a person's fall in a room using one inexpensive 10 GHz band Doppler sensor. The movement in the room is constantly monitored by the Doppler sensor and it is converted to the sequential spectrogram data. From the data, we construct a classifier for identifying dangerous "falling" movements among various movements of the human body by machine learning (LSTM) technique, and also developed a new real-time system to detect a person's falling behavior. In this paper, we describe our proposed method, experimental results and future plans.

Keywords: Doppler sensor, LSTM, Fall detection

1. はじめに

日本は現在、世界で最も高齢化が進んだ国となっており、今後もさらに少子高齢化が進むと予測されている。令和 2 年高齢社会白書[1]によると、総人口に占める 65 歳以上人口の割合（高齢化率）および 65 歳以上人口のうち一人暮らしの割合（独居高齢者率）は、2020 年時点で 28.9%および 22.4%、2030 年には 31.2%および 23.9%と推計され、独居高齢者は年々増加し続けている。単身世帯では自律度の高い生活を送ることができる一方で、在宅時の転倒や急病時に同居家族の通報や搬送等を期待できないため処置の遅れや、最悪の場合、孤独死等のリスクを伴う[2]。リスク回避の方法として、行政・社会的な施策と様々な高齢者見守りシステムを組み合わせた総合的な取り組みが求められている。そこで我々は、室内の独居高齢者を見守る ICT システムの開発について継続的に取り組んでいる。

例えば脳梗塞・心筋梗塞などでは急性の発症から 1~2 時間以内の救急処置が転帰を左右するといわれており、生命

の安全の確保と後遺症予防の観点から、独居高齢者が居室内で転倒するのを速やかに検出し早急にケアを行うことは非常に重要である。そこで近年、人物の転倒検知に関して、国内外で広く研究されている。転倒検知のために人体の動きデータを取得する方法としては、一般に、動画像センサや音響センサ、赤外線センサ、動きセンサ等を用いるパッシブな方法と、3 次元加速度センサ等と通信機器を一体化させた小型のウェアラブル・デバイスを対象人物に装着させる方法とに大別できる。しかし、前者の動画像センサを用いる方法はプライバシーの観点で、また後者の方法は手間・煩わしさの点で問題が大きい。そのため我々はこれまで、フロアマット型センサ、赤外線アレイセンサ技術等を活用した独居高齢者の転倒検知・介護者自動通知システムを開発し、実験を行ってきた[3,4]。

さらに近年、屋内（居室内）で使用可能な高精度かつ小型のドップラーセンサが入手できるようになったことを機に、ドップラーセンサを用いた信号処理手法が提案され、顕著な成果が得られている[5,6]。しかしながら高齢者世帯

¹ 福岡大学 工学部 電子情報工学科
Department of Electronics Engineering and Computer Science, Fukuoka University




図1 ドップラーセンサを用いた転倒検出・通報システムの全体構成

への設置を考えた場合、既存の手法では高精度ドップラーセンサの使用を前提とした高度な信号処理系の実装が必要であるためコストは下がりにくく、一般世帯への普及には相当なハードルが存在する。

我々は、安価なドップラーセンサと小型コンピュータボード、およびサーバで構成されるシステムを構築し、室内での人物の転倒を検出するための手法を提案し、その手法を実装した通報システムの構築を目指している[7, 8]。図1に全体構成を示している。

本手法では、ドップラーセンサで人物の動きを常時モニタリングし、センサからの信号を逐次、スペクトログラムに変換する。そしてスペクトラム化された時系列データをもとに学習用データセットを構築する。学習用データセットは「転倒」「しゃがむ」「横になる」の3分類とし、特に危険な「転倒」動作を識別するための分類器を機械学習手法によって構成する。また、この分類器を転倒検出のために用いる。危険だと判定された場合、インターネットを介して介護者へ通知し、介護者が迅速に適切な対応を取ることができるようにする。

我々の過去の発表[7, 8]では、分類器の生成のためにCNN（畳み込みニューラルネットワーク）手法を採用した。また学習用データセットの一部を検証用として分離して評価したところ、90~95%程度の精度で「転倒」を分類できた。

今回我々は、以前と同じ学習用データセットを用いつつも、機械学習手法としてCNNの代わりにLSTMを採用し、分類精度を引き上げることを目指した。また、ドップラーセンサから常時出力される信号に対して連続的に分類処理を行い、実時間で、人物の転倒行動を検出するシステムを新たに構築した。

次章では本研究に関する先行研究事例を概説する。第3章では、我々が開発している転倒検出システムの構成について概説する。第4章では学習用データセットの構成およびスペクトログラム化手法について概説する。第5章では今回新たにLSTM手法によって実装した分類器および実時間転倒検出システムの構成について概説する。第6章にて実験の概要・評価について述べた後、第7章にて結論および課題をまとめる。

2. 先行研究事例

マイクロ波ドップラーセンサとは、センサアンテナから照射される電波（マイクロ波）によって、対象の動きを信号として出力するモジュールである。センサが照射した電波（送信波）は対象物に当たって反射する際、周波数が対象物の移動速度に応じて微小に変化する。センサはその反射波（受信波）を受信することで、送信波と受信波の位相の差が、対象物体そのものあるいは一部位の移動速度に応じた周波数（ドップラー周波数）として得られる。また、この信号をIQ検波器という回路で検出し、その位相を調べることによって対象物体がどの程度の速度で接近しているかあるいは遠ざかっているかを判断することができる。

これまでに、ドップラーセンサを用いた転倒検出を目的とする信号処理手法はいくつか提案されている。

「電波を用いた転倒・転落システム」[5]ではアレイアンテナセンサとドップラーセンサ3台を用いて、「転倒」動作をSVM/K-NN手法によって検出する。「マイクロ波ドップラーセンサを活用した転倒検知」[6]では2台のドップラーセンサから得た信号をウェーブレット変換によって周波数特性を抽出し、転倒動作をHMM手法によって検出する。その他にも2台のレンジ・ドップラーレーダーを用いて、サポートベクターマシン（SVM）により転倒動作の特徴を分類する手法[9]等が提案されている。

しかしこれら従来手法では、高齢化世帯への設置を考えた場合、高精度センサを複数台使用することと、高度な信号処理系を実装することを前提としているためコスト低減がかなり難しいと思われ、一般世帯への普及には相当なハードルが存在する。

従来、マイクロ波ドップラーセンサによる行動認識の手法は、センサの信号データを時間と周波数のスペクトログラムに変換し、行動を分類するための特徴量を抽出するというものであった。その特徴量は、ドップラーセンサによるモニタリング対象の体長、習慣、健康状態等によって大きく異なるが、固定的な周波数レンジ、信号強度、行動時間であった。その場合、転倒・非転倒のような単純な行動識別に対しては有効であるが、例えばしゃがむ動作と座位

姿勢では特徴量の値がほぼ同じになってしまい、そのような似通った行動は識別しにくい。また、SVM や KMP, Sparse Bayesian などの方法では、必要なサポートベクトルの数が、通常、学習セットの大きさに応じて線形に増加してしまう。そこで、複雑さを抑えるためにエラー/マージンのトレードオフとして、サポートベクトル数を削減せざるを得ず、認識精度は落ちる懸念がある。その上、転倒検出処理を実現するためにはあらかじめ、使用するデータを事前に加工、抜き出し等を行った後、動きの分類に用いる必要があるが、このタスクは長い時間を要するだけでなく、非常に手間がかかる。そこで、転倒の特徴を自動的に求める分類手法が望まれるが、例えば、米国 Villanova 大学では転倒検出の精度を改善するために、深層学習の一手法であるオートエンコーダによる分類手法[10]が提案されている。しかし、この研究では1台のレンジ・ドップラーレーダーを使用しているが、かなりコストが高いという問題を有している。

また一般に、設置容易性、実装コストもさることながら、ドップラーセンサの使用は日本国内における電波法によって規制されるため、このような研究を進めるにあたっては、十分に留意しなければならない。

3. システムの構成

近年、ドップラーセンサはモノリシック・マイクロ波集積回路技術の進展により小型化され、アンテナ一体型モジュールとして、室内に設置する機器に組み込むことが可能になった。だが、これまでに提案されてきた転倒検出の信号処理・判定手法ではドップラーセンサ出力データの精度(S/N 比)や信号強度の安定性も重視され、そのような条件を満たすセンサのコスト低減は難しい。そもそも、システム全体の実装コスト、消費電力、システム重量、調達の容易性、設置の容易性等は重視されていなかった。

そこで我々はドップラーセンサ、民生用電子部品、8ビット MCU および組み込みコンピュータボードで構成された安価なかつ調達が容易なシステムを試作した(図1上)。我々は現在ドップラーセンサとして NJR4178J(新日本無線社製、パッチアンテナ一体型構造、10.5GHz 帯・屋内専用、アナログ出力)1個を用いている(図2上)。センサからの出力信号は汎用オペアンプ(NJM2734)で1万倍程度増幅された後、商用電源周波数によるハムノイズをカットする目的でノッチフィルタ(NF1とNF2)、さらにローパスフィルタ(LPF、遮断周波数=55Hz)を通過する。NF1,NF2,LPF 段も全て同じ汎用オペアンプを用いて構成する。アナログ回路は最終的に 4.0Vp-p, 2.5V オフセットの信号が生成されるよう調整する。このアナログ信号は 8ビット MCU (Microchip 社製 ATmega328P に内蔵される A/D 変換器(分解能: 10ビット、入力電圧レンジ: 0~5.0V)に入力され、以後はデジタル信号として扱われる。NF1, NF2 および LPF によって 60Hz 以上の信号はカットされているので、



型番: NJR1478J
外形: 46.5mm×40mm×12mm
中心周波数:
10.525±0.005GHz
動作電圧: +5.0±0.2V
消費電流: 30 mA




図2 ドップラーセンサおよび
ドップラーセンサ・ユニット内部の写真

シャノンの標本化定理に従い、MCU の A/D 変換データ・サンプリング周波数を 200Hz に設定する。これにより、A/D 変換によって生成されるデジタル・データストリームのバンド幅を抑制できるため、UART を介して PC1 への安定したデータ送信を保証する。

MCU は UART-USB 変換 IC を経由し、制御・データ収集・送信用 PC (PC1) との間に、コマンド制御・データ送信 I/F を提供する。PC1 は今回、Linux コンピュータ・ボード (Raspberry Pi 3) を用いる。また学習データ収集の際、被験者に動作開始指示を出すためのプロンプタが必要となる。そこで必要に応じて、動作開始タイミング・時間指示用 PC (PC2) を外付けするための I/F として、絶縁用フォトカプラおよび PIO-USB 変換 IC を備える。

今回の試作システムでは、ドップラーセンサから UART-USB 変換 IC までを ABS 樹脂製の筐体内部の構成部品として組み込み、ドップラーセンサ・ユニットとした(図2下)。筐体の大きさは A5 判サイズ、重量は約 300g である。センサのアンテナ面が筐体側面に垂直となるよう配置し(図2右上)、アンテナの指向性が水平方向に広がるようにした。

学習すなわち分類器作成処理および、転倒行動検出すなわち運用時の分類器判定処理はサーバが担う。サーバの処理負荷と通信量を削減するため、PC1 ではリアルタイムの簡易判定処理を行い、必要に応じて、サーバにおいて分類器を用いた分類処理を行うようにする。これにより低コスト・低消費電力化と、安定した判定精度・高レスポンスの両立を目指す。分類器において危険な「転倒」動作が判定され、実際に転倒行動の検出に至ったとき、サーバから介護者の端末へメッセージが通知される。通知処理系は過去




図3 学習用データセット，分類器の構築，実時間転倒検出システム実行までの流れ




図4 センサデータの例




図5 スペクトログラム化

の我々の実装成果物を流用する。

我々の当面の目標は，独居高齢者の居室内において人物の動きを検出した場合に，実時間転倒検出システムからの結果として，①転倒，②横になる，③しゃがむ，④何もしない，のいずれかに判定することである．具体的にはまず，①，②，③，④の判定を可能とする分類器を構築し，それ単体での評価を行うことである．次に，居室内へのドップラーセンサ・ユニットの設置を想定し，連続的にセンサから出力されるデータストリームに対して，その分類器を用いて，危険な「転倒」行動を実時間で検出可能なシステムを開発し，その実用性を検証することである．

2019年に我々はCNN（畳み込みニューラルネットワーク）手法を用いた分類器を構築し，我々の提案の妥当性の基本的評価として，分類精度の評価を行った．しかし現在，センサ信号の分類という点において，CNN手法に代わる新たな機械学習手法がいくつか提案されており，また，実時間での転倒検出システム内部の分類器として使いづらいことがわかった．そこで今回は人工回帰型ニューラルネットワークの一手法であるLSTM（長期-短期記憶 Long-Short Term Memory）手法を用いて分類器を生成する．図3は学習用データセットの収集・分類器の構築，そして実時間転倒検出システムの実行までの流れを示したものである．

4. 学習用データセットの構成およびスペクトログラム化手法

4.1 学習用データセット

学習に必要な教師データ群すなわち学習用データセットとしては，我々が2019年にCNN手法による実験を行ったときに用いたものを，そのまま再利用することにした．この2019年の実験では，20歳代の被験者8名（身長150～180cm）が①，②，③，④の動作をそれぞれ20～40回程度，動作開始から10秒間測定した．実験は発表者らが所属する大学の研究室（天井高さ：2.7m）の一部で行った．ドップラーセンサ・ユニットは，床からの高さ1.5m、被験者との水平距離4.0mの位置に設置した．USBケーブルでもってデータ収集用のPC（図1におけるPC1）が接続した．

データ収集のとき，室内照明としてインバータ式蛍光灯を点灯した．なお，照明に内蔵されるインバータ回路はハムノイズの発生源の一つであり，ドップラーセンサの信号にピークとして現れる．次に，大きなファンの回転は，ドップラーセンサの信号に定在的なピークとして現れ，その回転速度が可変であり一定でないため，我々が用いているセンサーユニット内部のアナログ・フィルタ回路では除去するのが困難である．したがって室内空調設備の電源を切った状態で収集を行った．その他，研究室の建物全体の微弱な振動に起因すると思われる定在波の存在が確認された

が、発生源の特定・対策は非常に難しく、収集したデータには、様々なノイズが含まれていた。

4.2 スペクトログラム化

MCU においてセンサ信号を A/D 変換・生成されたデータストリームは、PC1 が取得する。PC1 が取得したデータストリームのうち、①、②、③の例をそれぞれ図 4 上部に示す。PC1 ではセンサデータをテキストファイルフォーマットで保存・収集を行う。全てのファイルは LAN を経由して、サーバからアクセスされる。

サーバでは、全センサデータに対して短時間フーリエ変換処理を行い、スペクトログラム化データに変換する。また全てのスペクトラム・データ(例：図 4 下部)を保存・管理する。LSTM による分類器生成のための教師データとしては、センサデータをそのまま用いるのではなく、スペクトログラム化データを用いる。

スペクトログラムとは、時間軸上の波形信号を窓関数に通し、周波数スペクトルを計算した結果を指す。3 次元のグラフ(時間、周波数、信号成分の強さ)で表される。スペクトログラムを生成するために今回、短時間フーリエ変換(STFT)によって実現する。図 5 に短時間フーリエ変換の概要を示す。STFT は、時間変化する信号の周波数と位相の変化を解析するのによく用いられる。STFT は以下のように数式表現できる。(i は虚数単位)

$$STFT_{x,\omega}(t,\omega) = \int_{-\infty}^{\infty} x(\tau)\omega(\tau-t)e^{-i\omega\tau} d\tau$$

ここで $\omega(\tau)$ は窓関数であり、普通は $t=0$ 付近に中心をもつ山の概形をしていて、 $t=0$ 付近から離れると 0 になる関数である。 $x(t)$ は変換される関数(信号)、 $STFT_{x,\omega}(t,\omega)$ は時刻 t 、角周波数 ω のスペクトルを表現する複素数である。この手法では、与えられた信号に対してフレームサイズで窓関数を掛けて、その領域にてフーリエ変換(FFT)する。そしてフレームを時間軸上にずらしていきながら、同じように窓関数を掛けてフーリエ変換(FFT)をする。窓関数の領域でフーリエ変換された信号を時間軸上で重ね合わせることで、スペクトログラムのグラフを生成できる。実際には STFT の結果の絶対値を 2 乗したものをを使う。

$$\text{spectrogram}(t,\omega) = |STFT_{x,\omega}(t,\omega)|^2$$

結果、スペクトログラムは三次元グラフ(時間、周波数、振幅強度)で表される。図 4 下部では、横軸が周波数、縦軸が時間、各点の輝度がその周波数の振幅強度を表す。

4.3 データセットの生成処理

次に、スペクトログラム化を行ったデータに縮小処理を施し、実際の機械学習に用いるデータセットに変換する。今回、MCU の A/D 変換のサンプリング周波数は 200Hz(サンプリング間隔=5ms)であり、STFT の窓関数幅(図 5 中の ℓ)を 1280ms すなわち窓関数内の離散量=1280/5=256 個、窓関数のシフト量(図 5 中の N)を 64 すなわち 0.32 秒とする。60Hz 以上の成分は不要であるのでカットする。

また元々の収集データは 10 秒間の計測だったが学習データとして用いるにはデータ量がやや過大であり、7~8 秒間程度でも動作に関するデータは十分であると判断し、カットした。データは配列として扱われるが、スペクトログラム化データの各要素(周波数の振幅強度)値は浮動小数で表現されるため、それらを 0~255 の範囲の整数に収めるよう正規化を行う。さらに LSTM への入力に対応するよう、横 28×縦 56 行列に縮小・変換処理を行う。

変換したデータは、分類する動作別にディレクトリを分けて保存する。作成したデータセットは学習用データとテスト用データの 2 つに分けて管理する。

5. 分類器および実時間転倒検出システムの構成

5.1 分類器の構成

以前の発表に引き続き、本発表でも深層学習によって分類器の生成を行う。今回は人工回帰型ニューラルネットワークの一手法である LSTM(長期・短期記憶 Long-Short Term Memory)手法を用いて、転倒を判別するための分類器(学習モデル)を生成する。

用意したデータセットに動作の種類ごとにラベルを付与したものを入力(28 次元)として、隠れ層を 128 層、出力次元を 4 に設定する。今回の実装では Pytorch でもって tuple(学習用データセットとラベルのセット)全体をミニバッチに分割し Dataloader に変換したものを入力として用いて、分類器の生成を行った。出力層は 4 次元で「転倒」、「横になる」、「しゃがむ」、「何もしない(ほとんど動いていない)」の 4 動作を分類するよう学習を行った。LSTM 内部ではソフトマックス関数およびクロスエントロピー誤差を用いた。

図 6 に、バッファへの信号入力、STFT のための窓関数幅でのクリップ、STFT 処理、縮小変換されたスペクトログラム、LSTM で構成される分類器、分類出力に至る流れを概念的に示す。

5.2 実時間転倒検出システムの構成

LSTM 手法で生成された分類器を、そのまま実時間転倒検出で用いる。学習の段階では、図 6 の信号入力は学習用データセットであった。実際の分類処理では、ドップラーセンサで計測しながら得たデータストリームは入力バッファに蓄積され、末端 10 秒間のセグメントを切り出し、さらに STFT の窓関数幅を窓関数シフト量ずつずらしながら学習時と同じように処理(STFT など)を行って、生成済みの分類器に入力することで、予測ラベル(1: 転倒, 2: 横になる, 3: しゃがむ, 4: 何もしない)が得られる。そして 4 つの出力のうち最大値となったものが、その時系列データ・セグメントに対する分類結果となる。

分類処理中も、センサからのデータストリームが入力バ




図 6 入力および LSTM 分類器の概要

表 1 開発環境

使用ツール	Anaconda
使用ライブラリ	Pytorch v.1.7.1
使用言語	Python3.7.9

表 2 開発用 PC (暫定的な検出サーバ) の仕様

OS	Microsoft Windows10 Home (64bit)
CPU	Intel Core i7-9750H @2.6GHz
主記憶	8GB

ッファに格納され続ける。次のセグメントの処理に入る前に、任意のスライド時間分のデータ末端を廃棄する。そして入力データストリームに対して、スライド分だけ時間軸をずらしていきながら、連続的に分類処理を繰り返していくことで、実時間での動作検出を実現する。

また我々は今回、新たに実時間での転倒判定システムを実装した。本システムは前述の分類器からの結果を入力とする。「転倒」動作を分類したのちに「動いていない」動作の分類が一定時間続いた場合を、高齢者が転倒して動けない危険な状態であることを検出したものと定義したうえで、もしそれが検出されれば、介護者に通知を行う。また「転倒」を検出しても一定時間たたないうちに何か動きがあった場合は、通知は行わず実時間人物転倒検出を継続する。検出のためのシステム内部の状態遷移およびカウンタ変数 (count) 制御の概要を図 7 に示す。システム内部の状態遷移制御変数 count は、LSTM 分類器の判別結果が「転倒」であるときにインクリメントされる。一定回数 (今回は 20 回と設定する) 判定されたときに、介護者への通報を行う。通報処理は別プロセスで行われるものとし、判定システム自体は初期状態 (IDLE) に遷移する。

6. 実験・評価

6.1 分類器の精度検証

開発環境および開発に用いた PC の仕様を表 1, 表 2 に示




図 7 検出システム内部状態遷移の概要

表 3 生成した分類器による①②③④の分類精度

	1 回目	2 回目	3 回目
①転倒	95%	100%	95%
②横になる	90%	95%	90%
③しゃがむ	90%	90%	90%
④何もしない	100%	100%	100%

す。また本発表における実験評価では、暫定的に開発用 PC を検出サーバとして用いた。

まず、LSTM 手法で作成した分類器の分類精度の検証を行い、実時間での転倒検出に適しているかどうか評価した。学習用データは 720 個、検証用のテストデータは 80 個である。学習用データ 720 サンプルのデータを 3 回学習させ、ラベル①②③④各 20 枚のテストデータの内、正しく分類できたサンプルの割合を表 3 に示す。

結果として「①転倒」動作は約 95%、「②横になる」「③しゃがむ」動作は約 90%、「④何もしない」動作は 100%で分類できていることがわかった。なお、①転倒動作を②横になる動作として、②横になる動作を③しゃがむ動作として、また③しゃがむ動作を④何もしない動作に間違えて判別してしまうことがあった。④何もしない動作に関しては判別を間違えることはなかった。しかし、②～④のいずれの動作を①転倒動作と誤判定することはなかった。したがって、実時間転倒検出システムに特に重要な、①転倒動作と④何もしない(動いていない)動作の分類については 95%以上の高い精度で判別できるといえる。

6.2 実時間転倒検出システムの性能検証

また、今回新たに構築した実時間転倒検出システムの検出性能を検証した。ドップラーセンサを動作させ、PC1 およびサーバに連続的にデータストリームが送信されている状態で、以下の 3 つの動作を行った。

- ①転倒 (勢いよく倒れる) してから動かない
- ②横になって動かない
- ③しゃがんでから動かない

①, ②, ③の動作をそれぞれ 20 回ずつ行った。①ならば異常通知処理が行われ、②, ③ならば通知処理が行われな

<注>

Label 0 = 分類器①
Label 1 = 分類器②
Label 2 = 分類器③
Label 3 = 分類器④




図 8 実時間での分類器出力-転倒検出システムの動作例

表 4 検出システムの正常動作率

slide_size の値	①転倒	②横になる	③しゃがむ
250	95%	20%	90%
500	95%	30%	90%
1000	50%	90%	75%

れば、正常に検出システムが動作したものとして、その割合を調べた。また本システムは入力データストリームに対して、一定のスライド (slide_size) 時間分だけ時間軸をずらして 10 秒分のデータを区切りながら、連続的に分類処理を繰り返していく。そこで、スライド時間を変化させてみて、動作検出の割合がどう変化するか、あわせて調査した。具体的には slide_size の値そのものはデータサンプル数であり、今回は 250, 500, 1000 に設定 (サンプリング周波数=200Hz), すなわち 1.25 秒, 2.5 秒, 5.0 秒に設定して実験を行った。

なお、本実験での被験者は本論文作成者一人である。また分類器を構築するための学習用データセットのほうには、本実験の被験者に関する動作データは全く含まれていない。

実験結果を表 4 にまとめている。また実際の実時間での分類器出力と転倒検出システムの動作例を図 8 に示している。表 4 の結果から、本システムにおいて slide_size が 250 の場合、「転倒」と「しゃがむ」動作は 90%以上で検出できているが、「横になる」動作については高確率で誤作動 (誤通知) する。一方、slide_size が 1000 の時、①と③の正常動作率が落ちたのに対し、②の正常動作率が著しく上がっている。このような結果になった原因としては、①、②、③の動作の開始から終了までにかかる時間との関連性が挙げられる。「転倒」と「しゃがむ」動作はせいぜい 1~2 秒の動作であるのに対し、「横になる」動作は 5~6 秒ほどかかる動作である。そもそも「横になる」動作自体が『ゆっくりと「転倒する」』動作ともとられかねないものである。よって、slide_size が小さい場合、「横になる」動作のデータストリーム領域が半端な形で切り出され、それが「転倒」の動

作と似通ってしまうことが考えられる。

そのため slide_size を大きくすると「横になる」動作については正常に検出できるようになるものの、「転倒」や「しゃがむ」動作を検出できなくなるケースが増え、正常動作率が下がってしまう。

我々は、こういった誤作動を減らすべきであると考えているが、現状では困難と考えている。一つの解決策としては、危険と判定されたタイミングで介護者に通知する際に、単にメッセージを送るだけではなく、その時点においてイメージセンサで取得した部屋の状況を、本人の同意のもと、介護者に送信することなどが考えられる (常時カメラを起動させるわけではないため、プライバシーの問題を解決できる余地がある)。また、動作分類の種類およびデータセットの改良を検討する必要がある。

7. おわりに

安価なドップラーセンサを用いたセンサシステムを試作し、そのセンサシステムを使用して、危険な転倒動作を検出するシステムを、LSTM を利用した分類器を用いて作成および評価を行った。

今後の予定として、まずデータセット収集環境の見直しとデータセットの前処理の改善を検討した後、今回の実験よりも抜本的にデータの種類や数を増やすことを検討している。また、フィルタ回路で除去できなかったノイズ周波数帯が存在した。ノイズの原因としては冷蔵庫の存在や部屋周囲の空調機器、建物の振動などが考えられるが、それらの分類精度への影響を精査する必要がある。

今回用いたセンサーユニットは電波法改正に伴い、2022 年以降一切使用できない。そこで、上記と並行して、低コスト・利便性を維持しつつも、抜本的に新構成のセンサーユニットの開発に着手している。そこでは、ドップラーセンサの周波数帯を 25GHz 帯に引き上げて新電波法に対応させ、また回路の低ノイズ化、デジタルフィルタ化、複数のセンサーユニットの協調動作の実現を予定している。

謝辞 最初に本テーマに取り組んだ吉野春香氏（現パナソニックシステムソリューションズジャパン）および学習用データセットの作成にご協力頂いた皆様に、謹んで感謝の意を表する。本研究の一部は、福岡大学領域別研究部の助成を受けたものである。

参考文献

- [1] “内閣府 高齢社会白書”,
<https://www8.cao.go.jp/kourei/whitepaper/index-w.html>, (参照 2021-2-10).
- [2] “みずほ総研レポート vol.14, 2017”,
<https://www.mizuho-ir.co.jp/publication/report/mhir/014.html>, (参照 2021-2-10).
- [3] A. Hayashida, V. Moshnyaga, K. Hashimoto, “The Use of Thermal IR Array Sensor for Indoor Fall Detection”, Proc. of IEEE SMC 2017, pp.594-599, Oct. 2017.
- [4] T. Ryu, V. Moshnyaga, O. Tanaka, K. Hashimoto, “Sensing Technologies for In-Home Monitoring of People with Dementia”, Proc. of the 3rd IIAE ICISIP, pp.84-91, Sep. 2015.
- [5] S.Tomii and T.Ohtsuki, “Falling detection using multiple dopplersensors”, Proc. of IEEE Healthcom 2012, pp.196–201, Oct. 2012.
- [6] 柴 和彰, 籾木崇史, 栗原陽介, 「マイクロ波ドップラセンサを活用した転倒検知」, 情報処理学会 ASD 研究会, 2017-ASD-10, Vol.3, pp.1-8, 2017 年.
- [7] K. Hashimoto, H. Yoshino, V. Moshnyaga, “Development of Human Fall Detection System using Doppler Sensor and Machine Learning Technique”, On-site Proc. of Asia Pacific Conference on Robot IoT System Development and Platform 2019 (APRIS2019), Nov.1, 2019.
- [8] 橋本浩二, 吉野春香, モシニャガ ワシリー, “ドップラーセンサと機械学習による人物転倒検出システムの開発”, 情報処理学会 組込みシステムシンポジウム 2019 (ESS2019), pp.13-16, 9 月, 2019 年.
- [9] Y. Kim , H. Ling, “Human Activity Classification Based on Micro-Doppler Signatures Using a Support Vector Machine”, IEEE Trans. Geoscience Remote Sensing, Vol. 54, No.1, May 2009.
- [10] B. Jokanovic , M. Amin, “Fall Detection Using Deep Learning in Range-Doppler Radars”, IEEE Trans. Aerospace Electronic Systems, Vol. 54, No.1, Feb. 2018.