

オートエンコーダと OC-SVM を用いた転倒検出手法の開発 Development of a Fall Detection Method Using Autoencoder and OC-SVM

束野 通洋[†]
Michihiro Tsukano

峰野 博史[†]
Mineno Hiroshi

1. はじめに

高齢化が進む中、高齢者の転倒は深刻な問題となっている。高齢者の不慮の事故において、転倒は死亡の主要な原因であり、迅速な検知と対応が求められている。厚生労働省の統計によれば、転倒・転落・墜落は最も多い不慮の事故である[1]。また、転倒は活動制限を引き起こし、可動性や自立性に影響を及ぼす可能性がある。したがって、高齢者の生活の質を向上させるためには、転倒検出手法の開発が不可欠である。

転倒検出に関する研究動向[2]によると、初期の研究ではセンサデータと統計的手法を用いた閾値ベースの手法が採用されていたが、複雑な問題やノイズの多いデータに対してはパフォーマンスの低下が報告されている。最近では機械学習手法、特に深層学習手法が注目されている[3]。使用されるセンサには、IMU やスマートフォンなどのウェアラブルデバイスに搭載されている加速度センサやジャイロセンサがある。また、カメラや赤外線センサ、圧力センサ、床音響センサなども使用されている。機械学習アルゴリズムには、サポートベクターマシン（SVM）や畳み込みニューラルネットワーク（CNN）、長・短期記憶（LSTM）などの教師あり学習[4][5][6]が多く用いられており、高精度な結果が報告されている。

しかし、テスト環境では高精度な結果にもかかわらず、現実的な環境では精度が低下してしまうといった問題が挙げられている[2]。これは、現実的な環境では想定外の行動が発生している可能性がある。教師あり学習では、学習した行動に比べて、学習していない行動の推定精度は低い。この問題を解消するには、単純に多種多様な正常や転倒行動を大量に収集し、学習させる方法が考えられる。しかし、転倒行動を大量に収集することは現実的に困難である。そこで、比較的収集が容易な正常行動のみを学習し、正常と転倒行動を分類する教師なし学習の異常検知手法に着目した。

本稿の構成は以下の通りである。2 章では異常検知手法を用いた関連研究をまとめ、3 章では提案手法を示す。4 章では提案手法の評価実験および他手法との比較を行い、5 章ではまとめと今後の課題について述べる。

2. 関連研究

2.1 OC-SVM を用いた異常検知手法

One Class Support Vector Machine（OC-SVM）は正常データのみを学習し、未知のデータが正常か異常かを分類する

教師なし学習手法である。具体的には、図 1 のように異常データが原点に近くなるような空間に変換し、正常データと原点との距離が最大となる境界線を導出する。境界線より原点側が異常、その反対側を正常と分類する。




図 1 OC-SVM によるデータ分類のイメージ

先行研究では、正常行動のみを学習する異常検知手法を用いた車椅子の転倒検出システムが提案されている[7]。このシステムでは、加速度センサとジャイロセンサのデータが使用されている。機械学習アルゴリズムとしては、OC-SVM を単体で使用した場合と、統計的手法を組み合わせた閾値ベースの手法が提案されている。評価結果によると、OC-SVM 単体の F 値が 0.902 であり、統計的手法と組み合わせた閾値ベースの手法の F 値が 0.965 と報告されている。

2.2 オートエンコーダを用いた異常検知手法

オートエンコーダ（AE）は入力データと一致するデータを入力することを目的とした教師なし学習手法である。エンコーダ部分ではデータの次元数を削減し、デコーダ部分ではエンコーダのレイヤーを逆順に適用するネットワーク構造を持っている（図 2）。また、AE によって出力されたデータと入力データとの差を再構成誤差と呼ぶ。




図 2 AE のネットワーク構造

異常検知手法として AE を用いる場合、この再構成誤差が重要な指標となる。正常データを入力した場合、出力は入力データに近づくように学習されるため、再構成誤差は小さくなる。一方、学習されたモデルに異常データを入力すると、再構成誤差は大きくなる。したがって、再構成誤差はデータが正常か異常かを判断するための重要な要素となる。

先行研究では、AE と OC-SVM を組み合わせた DDoS 攻撃検出手法が提案されている[8]。この研究では、正常なトラフィック情報と一般的な 7 種類の攻撃に関するトラフィ

[†] 静岡大学大学院総合科学技術研究科 Graduate School of Integrated Science and Technology, Shizuoka University

ック情報を使用しており，正常なトラフィック情報のみを学習に使用した異常検知手法を採用している．AE は 13 次元の入力層から 2 次元まで次元数を削減し，再び 13 次元に戻すネットワークを構築している．次元削減された隠れ層の 2 つのユニットを特徴量として抽出し，OC-SVM を用いて正常と異常を分類する．評価結果では，AE と OC-SVM を組み合わせた手法の F 値が 0.991 であり，OC-SVM 単体の F 値が 0.972 であった．AE を組み合わせることにより効果的な結果が得られることが報告されている．

以上の関連研究をもとに，AE と OC-SVM を組み合わせた転倒検出手法の開発を目指す．

3. 提案手法

3.1 アーキテクチャ

図 3 に提案手法のアーキテクチャを示す．データは加速度センサとジャイロセンサから収集された行動データを使用し，異常検知手法を用いて転倒検出を行う．

処理の流れとしては，学習フェーズと推論フェーズの 2 つがある．学習フェーズでは，正常行動データのみを使用し，前処理を施した後，3 つの特徴量を算出する．機械学習アルゴリズムには OC-SVM を用いて学習を行う．推論フェーズでは，正常と転倒行動データの両方を使用する．学習フェーズと同様の工程を実施し，学習済みモデルを用いて正常と転倒行動を分類する．




図 3 提案手法のアーキテクチャ

3.2 データセット

図 3 (a) データセットについて説明する．転倒検出用データセットとして，一般に公開されている SisFall データセット[9]を使用する．このデータセットは，2 種類の加速度センサと 1 種類のジャイロセンサが搭載されているデバイスを被験者の腰に固定して収集したものである．サンプリング周波数は 200Hz で，行動の種類ごとに 12 秒から 100 秒の間で計測されている．被験者には 19~30 歳の若者 23 人と，60~75 歳の高齢者 15 人が含まれている．各被験者は 19 種類の日常生活動作と 15 種類の転倒を実施し，それぞれ 5 回ずつ試行している．本研究では，日常生活動作を正常行動データとして扱う．正常行動の一覧を付録 A，転倒行動の一覧を付録 B に記載する．

3.3 前処理

図 3 (b) 前処理について説明する．まず，データセットの計測時間には違いがあるため，時間間隔の調整を実施した．方法としてはデータの後半を除去し，12 秒に統一した．また，正常行動データの中で 25 秒の行動が 3 種類存在し，これらの行動は特徴が失われる可能性があるため，研究対象から除外した．さらに，正常行動データの中に転倒を示唆する行動 (D11) があり，正常行動かどうかの判断が困難であったため，これも研究対象から除外した．また，行動の種類に関わらず，外れ値によって特徴が失われたデータも確認されたため，それらのデータも除外した．

次に，3 軸の合成値を算出した．この値は，データ収集デバイスの向きや位置に関わらず特徴を得ることができる [10]．式 (1) に合成値の算出式を示す．

$$\text{合成値} = \sqrt{x^2 + y^2 + z^2} \quad (1)$$

最後に，スケールの調整や処理高速化のために，全データに対して，正規化を実施した．式 (2) に正規化の算出式を示す．

$$x_{norm}^i = \frac{x^i - x_{min}}{x_{max} - x_{min}} \quad (2)$$

3.4 特徴量抽出

3.4.1 特徴量 1：最大値 / 平均値

図 3 (c) 特徴量 1 について説明する．図 4 は正常と転倒行動データの一例で，正規化済み合成加速度を時系列に表示したものである．上の段が正常行動データ，下の段が転倒行動データを示している．




図 4 正常と転倒行動データの一例

転倒行動データの合成加速度は，転倒時に大きな値を示し，それ以外では，比較的小さな値になることが観察された．ある程度の時間間隔があるデータであれば，転倒による影響と正規化により，大部分は小さな値になるため，平均値は小さくなると考えた．一方で，正常行動データは転倒行動データと比較すると，転倒の影響を受けないため，平均値は大きくなると考えた．それぞれ平均値を算出したところ，正常行動データは，0.303，転倒行動データは，

0.074 と想定通りの結果になった．これらの結果をもとに，転倒の影響で平均値が小さくなることを考慮し，最大値と平均値の離れ具合を示す指標を検討した．したがって，最大値から平均値を割った値を 1 つ目の特徴量として使用する．

3.4.2 特徴量 2：1 次階差の標準偏差

図 3 (d) 特徴量 2 について説明する．転倒時の合成加速度の変化に注目し，階差を特徴量として採用した．階差とは，連続する時系列データにおいて隣り合うデータの差を指す．図 5 は図 4 の正常と転倒行動データの一例を 1 次階差にしたものである．上の段が正常行動データの 1 次階差，下の段が転倒行動データの 1 次階差を示している．転倒行動データのばらつきは，正常行動データのばらつきと比較して小さいことが観察された．それぞれ標準偏差を算出したところ，正常行動データは，0.050，転倒行動データは，0.024 となった．また，転倒行動データの 1 次階差のばらつきは，元データのばらつきと比較して，より小さくなることが観察できる．これは，転倒時の合成加速度の急激な変化に比べ，転倒時以外の行動は緩やかな変動であるため，階差によって除去されたことが考えられる．




図 5 正常と転倒行動データの 1 次階差




図 6 転倒行動データの n 次階差の標準偏差

さらに，階差の有効性を検証するため，0 から 200 次階差の標準偏差を調査した．図 6 に転倒行動データの n 次階

差の標準偏差を示す．結果は $n = 1$ の階差の標準偏差が最も小さくなることが明らかになった．したがって，1 次階差の標準偏差を 2 つ目の特徴量として使用する．

3.4.3 特徴量 3：AE による再構成誤差

図 3 (e) 特徴量 3 について説明する．図 7 に AE のネットワーク構造（提案手法）を示す．




図 7 AE のネットワーク構造（提案手法）

まず，入力層では，加速度センサ (x, y, z) とその合成値，ジャイロセンサ (x, y, z) とその合成値の 8 次元の正常行動データを入力データとする．表 1 に AE の入力データを示す．処理高速化のため，サンプリング周波数ごとに最大値を取得し，1 秒に 1 回のデータになるように調整した．

表 1. AE の入力データ

加速度センサ	ジャイロセンサ
加速度 x	ジャイロ x
加速度 y	ジャイロ y
加速度 z	ジャイロ z
加速度データの合成値	ジャイロデータの合成値

次に，隠れ層では全結合層と標準化層を設定し，活性化関数には ReLU 関数を採用した．全結合層の次元数は 8, 4, 8 と変化するように構築した．入力と出力には同じ正常行動データを適用し，再構成誤差が小さくなるように学習する．推論時には，正常行動データが入力されると，再構成誤差は小さくなり，転倒行動データが入力されると，再構成誤差は大きくなることが期待される．したがって，AE から得られる再構成誤差を 3 つ目の特徴量として使用する．

4. 評価実験

4.1 データセットの分割

本実験で用いた SisFall データセットは，学習，検証，テストの 3 つの項目に分割される．行動の種類の偏りを防ぐために，各項目でデータが網羅されるような分割方法を検討した．SisFall データセットは，行動の種類ごとに 5 回ずつ試行されている．試行回数を利用して，種類を均等に分割した．試行 1 回目から 5 回目をそれぞれ R01, R02, R03, R04, R05 と表す．教師なし学習の異常検知手法を用いるため，学習では正常行動データの R01 と R02 を使用する．

検証では正常行動データの R03 を使用し、テストでは正常行動データの R04 と R05、および同程度の量を考慮して、転倒行動データの R01 と R02 を使用する。表 2 に各項目で使用する試行データを示す。データ数は、学習が 851、検証が 350、テストが 1368（正常行動データが 696、転倒行動データが 672）となった。

表 2. 各項目で使用する試行データ

	正常行動データ	転倒行動データ
学習	R01, R02	-
検証	R03	-
テスト	R04, R05	R01, R02
未使用	-	R03, R04, R05

4.2 学習設定

AE の最適化アルゴリズムには Adam を選択し、学習率を 0.001、損失関数を平均二乗誤差（MSE）に設定した。この設定により、AE による再構成誤差は MSE となる。また、バッチサイズを 16、エポック数を 100 に設定した。

OC-SVM の学習には、RBF カーネルを選択した。ハイパーパラメータ（ ν , γ ）は、 k 分割交差検証を併用したグリッド探索アルゴリズムを使用し、F 値に基づいて調整した。 k には 3 を設定した。 ν の値は、 $\nu = [0.001, 0.35]$ の範囲を設定し、 γ の値は、 $\gamma = [0.001, 3]$ の範囲を設定した。最良な結果として（ ν , γ ）=（0.1, 2）が得られた。

4.3 評価結果

まず、AE の評価について説明する。図 8 に AE の学習結果である学習曲線を示す。




図 8 AE の学習曲線

学習データにおける損失を loss、検証データにおける損失を val_loss で示し、両者ともに減少し、低い値で収束していることから、十分に学習されたことが確認できた。また、図 9 に正常と転倒行動のテストデータを用いた AE の学習済みモデルによる推論結果の箱ひげ図を示す。正常行動データ（normal）と転倒行動データ（abnormal）の MSE の平均値がそれぞれ約 0.009 と約 0.027 という結果となり、転倒行動データの MSE が高い傾向にあることを示した。




図 9 AE による推論結果の箱ひげ図

次に OC-SVM の評価について説明する。図 10 に OC-SVM に対する学習データである 3 つの特徴量を可視化したものを示す。




図 10 OC-SVM の学習データの可視化

3 つの特徴量とは、前章で紹介した最大値/平均値、1 次階差の標準偏差、AE による MSE である。normal が正常行動のテストデータ、abnormal が転倒行動のテストデータである。図 10 (b) 最大値/平均値の軸に注目すると、正常行動データが 0 に近く、転倒行動データが 0 から遠ざかっている傾向が観察された。図 10 (c) 1 次階差の標準偏差に注目すると、正常行動データは 0 から遠ざかり、転倒行動データは 0 に近くなる傾向が観察された。図 10 (a) AE による MSE に注目すると、正常行動データは小さな値でまとまり、転倒行動データは大きな値でまとまっている傾向が観察された。

図 11 に正常と転倒行動のテストデータを用いて OC-SVM の学習済みモデルによる推論結果の混同行列を示す。実際の正常行動データを正常と予測した数は 636、転倒と予測した数は 60 となった。また、実際の転倒行動データ

を転倒と予測した数は 616，正常と予測した数は 56 となった。




図 11 OC-SVM による推論結果の混同行列

評価指標には，式 (3) 正解率，式 (4) 適合率，式 (5) 再現率，式 (6) F 値を用いる。真陽性 (TP) は実際の正常行動データに対して，正常と予測したものを指す。偽陽性 (FP) は実際の転倒行動データに対して，正常と予測したものを指す。偽陰性 (FN) は実際の正常行動データに対して，転倒と予測したものを指す。真陰性 (TN) は実際の転倒行動データに対して，転倒と予測したものを指す。評価指標から提案手法の正解率は 0.915，適合率は 0.919，再現率は 0.914，F 値は 0.916 を示した。

$$\text{正解率 (Accuracy)} = \frac{TP + TN}{TP + TN + FP + FN} \quad (3)$$

$$\text{適合率 (Precision)} = \frac{TP}{TP + FP} \quad (4)$$

$$\text{再現率 (Recall)} = \frac{TP}{TP + FN} \quad (5)$$

$$\text{F 値 (F1-score)} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (6)$$

4.4 手法の比較

表 3 に提案手法と比較して，4 つの異なる手法の評価結果を示す。A 手法は，OC-SVM 単体の手法である[7]。特徴量としては，提案手法で用いた特徴量 1 と 2 を使用した。この手法の F 値は 0.884 で，提案手法よりも低いスコアを示した。これは，OC-SVM 単体よりも AE を組み合わせた方が有効であることを示唆している。

B 手法は，AE 単体の手法である。提案手法と同じネットワーク構造を使用し，得られた MSE から算出された閾値を用いて正常と転倒行動を分類した。式 (7) に閾値の算出式を示す。正常行動の第三四分位数を $q3_{normal}$ ，転倒行動の第一四分位数を $q1_{abnormal}$ と表す。また，図 9 に正常と転倒行動のテストデータを用いた推論結果の箱ひげ図を示している。推論時に MSE が閾値以下であれば正常行動とし，閾値を超えていれば転倒行動と分類する。この手法の F 値は 0.917 で，提案手法と同程度のスコアを示

した。しかし，閾値ベースの場合，使用したデータセット以外ではパフォーマンスが低下する可能性が高いため，機械学習ベースの提案手法が優位であると考えられる。

$$\text{閾値} = q3_{normal} + \left(\frac{q1_{abnormal} - q3_{normal}}{2} \right) \quad (7)$$

C 手法は，AE による次元削減された隠れ層の 2 つのユニットを特徴量とした OC-SVM の手法である[8]。提案手法の特徴量 3 の代わりに，隠れ層の 2 つのユニットを特徴量とし，合計 4 つの特徴量を用いた。また，全結合層の次元数が 8，2，8 と変化するようにネットワークを構築した。この手法の F 値は 0.880 で，提案手法よりも低いスコアを示した。これは，次元削減された隠れ層から得られた特徴量よりも MSE を特徴量とした方が有効であることを示唆している。

D 手法は，AE の層を増やした積層 AE (SAE) と OC-SVM を組み合わせた手法である。全結合層の次元数が 8，4，2，4，8 と変化するようにネットワークを構築した。この手法の F 値は 0.914 で，提案手法と同程度のスコアを示した。これは，単に層を増やしたことによる精度の向上は見られなかったことを意味している。

表 3. 手法ごとの各評価指標における評価

	手法	正解率	適合率	再現率	F 値
A	OC-SVM [7]	0.878	0.856	0.914	0.884
B	AE (閾値)	0.912	0.888	0.947	0.917
C	AE+OC-SVM [8]	0.880	0.898	0.862	0.880
D	SAE+OC-SVM	0.913	0.920	0.908	0.914
E	提案手法	0.915	0.919	0.914	0.916

5. おわりに

本研究では，ウェアラブルデバイスに搭載されている加速度センサとジャイロセンサのデータを用いて転倒検出手法を開発した。特に，高齢者の転倒行動データを大量に収集することは困難であるため，比較的収集が容易な正常行動データのみを学習する教師なし学習の異常検知手法に着目した。関連研究をもとに，AE と OC-SVM を組み合わせた機械学習ベースの手法を提案した。評価実験では，一般に公開されている SisFall データセットを使用し，F 値が 0.916 を示した。また，OC-SVM 単体手法と比較した結果，転倒検出手法として，AE を組み合わせることは有効であることが明らかになった。

今後の課題としては，検出精度の向上に向けて，本研究の評価結果で示された誤分類データを分析することが考えられる。誤分類データに関しては，正常行動データが 60 件，転倒行動データが 56 件存在している。これら合計 116 件の誤分類データを正しく分類するように手法を改善することで，検出精度の向上を実現できる。また，リアルタイム検出の観点から，本研究では入力データの時間間隔を 12 秒に調整しているが，時間間隔をより短くすることについても検討事項として挙げられる。

他には，データセットの拡充が必要である。異常検知手法は，学習に使用した正常データ以外を異常と分類する可能性が高いため，学習に使用しなかった正常行動を転倒と

分類する可能性がある。したがって、より多くの多種多様な正常行動データを収集し、学習させることが必要である。また、汎化性能の観点から SisFall データセットに対してのみ高精度な結果になる可能性があるため、他のデータセットを併用する必要があると考える。

参考文献

- [1] 厚生労働省, “死因簡単分類別にみた性別死亡数・死亡率（人口 10 万対）”, 令和 4 年（2022）人口動態統計（確定数）の概況, https://www.mhlw.go.jp/toukei/saikin/hw/jinkou/kakutei22/dl/11_h7.pdf (2024/06/10 閲覧).
- [2] Usmani, Sara, Abdul Saboor, Muhammad Haris, Muneeb A. Khan, and Heemin Park, “Latest Research Trends in Fall Detection and Prevention Using Machine Learning: A Systematic Review”, *Sensors* 2021, Vol.21, No.15: 5134 (2021).
- [3] M. M. Islam et al., “Deep Learning Based Systems Developed for Fall Detection: A Review”, in *IEEE Access*, Vol. 8, pp. 166117-166137 (2020).
- [4] Alizadeh J, Bogdan M, Classen J, Fricke C, “Support Vector Machine Classifiers Show High Generalizability in Automatic Fall Detection in Older Adults”, *Sensors* 2021, Vol. 21, No. 21: 7166(2021).
- [5] H. Yhdego, J. Li, S. Morrison, M. Audette, C. Paolini, M. Sarkar, H. Okhravi, “Towards Musculoskeletal Simulation-Aware Fall Injury Mitigation: Transfer Learning with Deep CNN for Fall Detection”, 2019 Spring Simulation Conference (SpringSim), pp. 1-12 (2019).
- [6] M. M. Kabir, J. Shin and M. F. Mridha, “Secure Your Steps: A Class-Based Ensemble Framework for Real-Time Fall Detection Using Deep Neural Networks”, in *IEEE Access*, Vol.11, pp. 64097-64113 (2023).
- [7] Sofia Yousuf Sheikh, Muhammad Taha Jilani, “A ubiquitous wheelchair fall detection system using low-cost embedded inertial sensors and unsupervised one-class SVM”, *Journal of Ambient Intelligence and Humanized Computing*, Vol.14, pp. 147-162 (2023).
- [8] L. Mhamdi, D. McLernon, F. El-Moussa, S. A. R. Zaidi, M. Ghogho and T. Tang, “A deep learning approach combining autoencoder with one-class svm for ddos attack detection in sdns”, 2020 IEEE Eighth International Conference on Communications and Networking (ComNet), pp. 1-6 (2020).
- [9] Sucerquia, Angela, José David López, and Jesús Francisco Vargas-Bonilla, “SisFall: A Fall and Movement Dataset”, *Sensors* 2017, Vol.17, No.1: 198 (2017).
- [10] 伊吹真俊, 宮城茂幸, “3 軸加速度センサを用いた歩行状態識別に有効な特徴量に関する一検討”, *情報科学技術フォーラム講演論文集*, Vol.12, No.3, pp. 441-444 (2013).

付録 A SisFall データセットの正常行動一覧

表 4. SisFall データセットの正常行動一覧

Code	Activity	Trials	Duration
D01	Walking slowly	1	100 s
D02	Walking quickly	1	100 s
D03	Jogging slowly	1	100 s
D04	Jogging quickly	1	100 s
D05	Walking upstairs and downstairs slowly	5	25 s
D06	Walking upstairs and downstairs quickly	5	25 s
D07	Slowly sit in a half height chair, wait a moment, and up slowly	5	12 s
D08	Quickly sit in a half height chair, wait a moment, and up quickly	5	12 s
D09	Slowly sit in a low height chair, wait a moment, and up slowly	5	12 s

D10	Quickly sit in a low height chair, wait a moment, and up quickly	5	12 s
D11	Sitting a moment, trying to get up, and collapse into a chair	5	12 s
D12	Sitting a moment, lying slowly, wait a moment, and sit again	5	12 s
D13	Sitting a moment, lying quickly, wait a moment, and sit again	5	12 s
D14	Being on one's back change to lateral position, wait a moment, and change to one's back	5	12 s
D15	Standing, slowly bending at knees, and getting up	5	12 s
D16	Standing, slowly bending without bending knees, and getting up	5	12 s
D17	Standing, get into a car, remain seated and get out of the car	5	25 s
D18	Stumble while walking	5	12 s
D19	Gently jump without falling (trying to reach a high object)	5	12 s

付録 B SisFall データセットの転倒行動一覧

表 5. SisFall データセットの転倒行動一覧

Code	Activity	Trials	Duration
F01	Fall forward while walking caused by a slip	5	15 s
F02	Fall backward while walking caused by a slip	5	15 s
F03	Lateral fall while walking caused by a slip	5	15 s
F04	Fall forward while walking caused by a trip	5	15 s
F05	Fall forward while jogging caused by a trip	5	15 s
F06	Vertical fall while walking caused by fainting	5	15 s
F07	Fall while walking, with use of hands in a table to dampen fall, caused by fainting	5	15 s
F08	Fall forward when trying to get up	5	15 s
F09	Lateral fall when trying to get up	5	15 s
F10	Fall forward when trying to sit down	5	15 s
F11	Fall backward when trying to sit down	5	15 s
F12	Lateral fall when trying to sit down	5	15 s
F13	Fall forward while sitting, caused by fainting or falling asleep	5	15 s
F14	Fall backward while sitting, caused by fainting or falling asleep	5	15 s
F15	Lateral fall while sitting, caused by fainting or falling asleep	5	15 s