

# 衣類型圧力センサとVAEを用いた日常生活行動中の無自覚打撲検知の実現に向けて

小野瀬 良佑<sup>1</sup> 榎堀 優<sup>1</sup> 間瀬 健二<sup>1</sup>

**概要:** 受傷理由不明の打撲が認知症高齢者の介護において問題となっている。事故の発生時刻や、衝撃を受けた箇所がわかれば、受傷理由を特定するために有用である。本稿では、我々が過去に提案した衣類型圧力センサを用いて体表面の圧力値を計測し、異常な衝撃成分の検知を試みる。打撲による衝撃はパターン数が多いと考えられ、学習モデル内での網羅が難しいため、正常データパターンからの距離を異常スコアとして判定する、教示なし異常検知手法を導入する。一般的に、再構成誤差を損失とした生成ネットワークは、学習に用いたデータパターンを再構成することができる。日常生活のデータパターンのみを学習させた生成ネットワークは、日常生活に発生しづらい衝撃成分は再構成できず失敗すると考えられる。この特性を活かし、再構成誤差を異常スコアとして、再構成誤差の大きいデータを異常として検知する。学習させる正常データとして必要な日常生活の衣類上の圧力変化パターンを収集するために、7名の被験者を対象として衣類型圧力センサ着用時の日常生活行動を想定した圧力変化値を計測した。日常生活のデータパターンを収集するために、被験者に8つの日常生活タスクを課した。提案手法を評価するための衝撃データを得るために、衝撃の圧力変化成分をマネキンを用いて別撮りし、正常データに重ね合わせることで擬似的に作成した。擬似衝撃データを用いて提案手法を評価した結果、異常検知のROC-AUC値は  $0.718 \pm 0.029$  に達した。

## A Pilot Study of Unaware Bruise Detection Using a Garment-type Pressure Sensor and VAE

RYOSUKE ONOSE<sup>1</sup> YU ENOKIBORI<sup>1</sup> KENJI MASE<sup>1</sup>

### 1. はじめに

受傷理由不明の打撲が認知症高齢者の介護において問題となっている。三田谷らの報告によると、介助行為や見守りを行っていない状況下での転倒事故が多く確認されている [1]。同報告によると、受傷理由不明の打撲は、生活全般にわたって介護が必要な被介護者に多く発生している。特に、重度な認知症高齢者は意思疎通が難しいために、事故が発生したとしてもどのような事故が発生したかを介護者に説明できない。事故の発生時刻や、衝撃を受けた箇所がわかれば、受傷理由を特定するのに有用である。また、介護者が全身状態を調査しない場合などに、受傷そのものが見逃される危険も回避できる。

近年安価に入手できるようになったセンサや携帯端末を

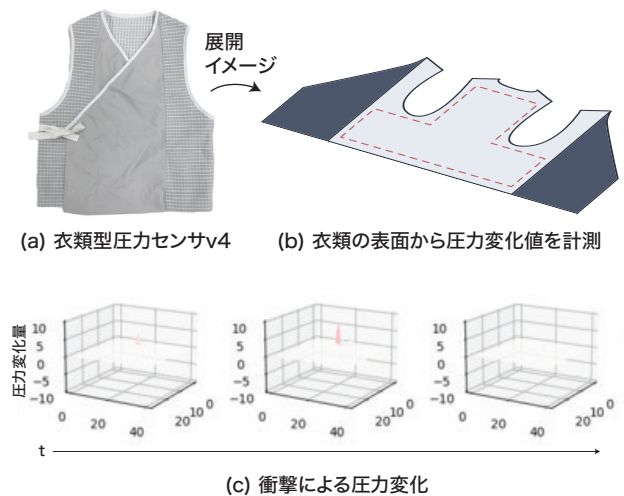


図 1 衣類型圧力センサと異常な衝撃値の可視化例

<sup>1</sup> 名古屋大学 情報学研究科

用いて、利用者の日常生活行動 (ADL: Activities of Daily Living) の認識や、転倒検知の研究が行われてきた。特に加速度を用いた転倒検知技術は実用化が進んでおり、市販のスマートウォッチにも転倒検知機能が組み込まれている [2]。しかし、歩行中に転倒せずに物に追突した場合や、衝撃を受けた箇所の特定まで行う研究は不十分である。これまでに、体表の広範囲を計測可能なセンサがなかったためである。

そこで、我々が過去に提案した衣類型圧力センサ [3] を用いて体表面の圧力値を計測することで、異常な衝撃成分の検知を試みる。衣類型圧力センサは体表面の全面を隙間なく計測でき、本用途に好適であると考えられる。図 1 に衣類型圧力センサ (a, b) と、マネキンに着用させた上で衝撃を加えた時の出力値を示す (c)。

一方で、問題となる衝撃の種類は多岐に渡り、学習データ内での網羅は難しい。そこで、正常データパターンからの距離を異常スコアとして判定する教師なし異常検知手法を衝撃検知に導入し、異常衝撃の検知モデルの初期検討を行うことを目的とする。教師なし異常検知手法として、動画像処理の分野で成果を上げている生成ネットワークの再構成誤差を利用する方法を用いる。一般的に、再構成誤差を損失とした生成ネットワークは、学習に用いたデータパターンを再構成することができる。日常生活のデータパターンのみを学習させた生成ネットワークは、日常生活中に発生しづらい衝撃成分は再構成できずに失敗すると考えられる。この特性を活かし、再構成誤差を異常スコアとして、再構成誤差の大きいデータを異常として検知する。本稿では、初期検討に用いる生成ネットワークとして、潜在空間表現を標準正規化することで情報圧縮性能と復号性能を両立している VAE (Variational Autoencoder) [4] を用いる。

提案手法の評価にあたり、衝撃データを含むデータの収集が困難であった。衣類型圧力センサの着衣者に受傷を指示することは倫理上不可能なためである。そこで、機械学習分野で学習データを水増しするために用いられるデータ拡張 (Data Augmentation) の考え方を応用し、擬似的に衝撃を含むデータを生成し、評価用データとして用いる方針をとる。擬似異常データ作成のために、マネキンで別撮りした衝撃由来の圧力値を重ね合わせる。圧力値の重ね合わせに対処するため、圧力値を圧力変化値に変換した値を用いることとした。

日常生活の衣類上の圧力変化パターンは、被験者に 8 つの日常生活タスクを課して収集した。擬似衝撃データを用いて提案手法を評価した結果、異常検知の ROC-AUC 値は  $0.718 \pm 0.029$  であった。

## 2. 関連研究

### 2.1 認知症高齢者の受傷理由不明の打撲

認知症高齢者の介護において、受傷理由不明の打撲が問題となっている。三田谷らの報告によると、介助行為や見守りを行っていない状況下での転倒事故が多く確認されている [1]。同報告によると、受傷理由不明の打撲は、生活全般にわたって介護が必要な被介護者に多く発生している。特に、重度な認知症高齢者は意思疎通が難しいために、事故が発生したとしてもどのような事故が発生したかを介護者に説明できず、問題であると指摘している。また、河野らによる研究では、一日の時系列に沿った事故発生状況の分析から、起床や就寝、朝食やお茶、夕食などの移動を伴う活動の際に、転倒事故が発生していると報告されている [5]。

### 2.2 カメラ画像やウェアラブルセンサを用いた転倒検知

転倒検知のために、カメラ画像やウェアラブルセンサを用いた研究がなされている。カメラ画像を使った近年の研究では、Kinect を使って床と人の重心距離を計算し、位置認識から転倒検知に応用する Panahi らの研究がある [6]。カラー画像のみや、慣性センサを用いた類似の研究よりも精度がよく、感度 100%、特異度 97.5% であったことを報告している。慣性センサのみを使った転倒検知は実用化が進んでおり、市販のスマートウォッチにも転倒検知機能が組み込まれている [2]。慣性センサのみを使って実際の転倒動作を含むデータセットで評価した Koo らの研究では、5 種類のランキングアルゴリズムを用いることで、100% に近い精度を報告している [7]。

これらの手法ではカメラや IMU などの既存のセンサを使って簡易に転倒検知可能だが、歩行中に転倒せずに物に追突した場合や、衝撃を受けた箇所の特定まで行う研究は不十分である。これまでに、体表の広範囲を計測可能なセンサがなかったためである。

### 2.3 教師なし異常検知手法

機械学習を用いた異常検知手法では、正常・異常ラベルがある場合には、二値識別モデルにより実現できる。しかし、工業製品の欠陥の検知課題のような、異常の発生頻度が小さく、様々なパターンの異常が発生しうる課題に対し、二値識別モデルを設計するのは難しい。そこで、既知のデータパターンと未知のデータパターンを分離可能な異常スコアを出力する教師なし異常検知手法が研究されている。

教師なし異常検知手法には、統計量を異常スコアをする手法や、生成ネットワークを使う手法がある。近年、動画像の教師なし異常検知で成果を上げている [8] 生成ネットワー

クを用いる手法では、学習に用いていないパターンのデータは、画像の再構成に失敗する特性を教師なし異常検知に応用している。また、再構成損失の大きい空間方向位置を算出することで、異常箇所の特長も可能である。これらの研究では異常検知の対象を画像としているが、ニューラルネットワークの2次元畳込み部分を3次元に置換することで、時系列の2次元画像にも拡張可能である。本稿では、初期検討に用いる生成ネットワークとして、潜在空間表現を標準正規化することで情報圧縮性能と復号性能を両立しているVAE (Variational Autoencoder) [4]を用いる。VQVAE (Vector-Quantized Variational Autoencoder)[9]など、後続の改良モデルも提案されているが、検討すべきパラメータ数も多いため、ネットワーク構成を簡素に保ちやすいVAEを初期検討に用いた。

### 3. 衣類型圧力センサ

本研究では我々が過去に [3] 提案した衣類型圧力センサの改良版である衣類型圧力センサ v4 を用いた。

センサの外観を図 1 (a) に示す。衣類の圧力センサ部分には、榎堀らが [10] で提案した布圧力センサを用いており、格子状に並ぶ計測点により圧力分布を計測できる。圧力分布の計測範囲は図 1 (b) で示す箇所であり、背面から胴回りを覆うように配置されている。

衣類型圧力センサを構成する布圧力センサは、導電糸の経緯間の距離変化を静電容量変化値として計測し、圧力変化値を得る。感圧部位は約 8mm 四方、非感圧部位は約 2mm で、感圧部位の間隔が約 10mm となるように、非導電糸と導電糸が格子状に配置されるように平織されている。計測点数の制約から、4つの感圧部位を1つとするように配線し、静電容量計測ユニットに接続した。静電容量計測ユニットは、最大約 2Hz で計測可能な設定とした。

### 4. VAE を用いた教師なし異常検知手法

前節で述べた衣類型圧力センサから取得した圧力変化値に含まれる異常な衝撃を VAE (Variational Autoencoder) [4] を用いて検知することを検討した。

初期検討における教師なし異常検知モデルの構成は、図 2 に示す通りとした。異常検知モデルは、再構成データ出力部と、異常スコア算出部の2段階で構成される。

第一段階の再構成データ出力部は、VAE を用いて入力値をエンコーダにより圧縮、デコーダを用いて再構成する役割を持つ。生成ネットワークの入出力は2次元の圧力変化値に固定長フレームの時間方向も足し合わせた3次元のデータとした。異常検知対象である衝撃成分は、時空間両方向に対して異常な変化パターンを呈するため、時空間両方向に対しての畳み込みの重みを学習すべきだと考えられる。従って、VAE のエンコーダとデコーダは3次元の畳み込み層を持つ構成とした。

第二段階の異常スコア算出部は、入力データと再構成データを比較し、異常スコアとして出力する役割を持つ。学習に用いていない異常成分は VAE による再構成が難しいと考えられるため、入力データと再構成データの差分を計算することで、異常部分を割り出すことができると考えられる。本稿における検討では、入力データに対する再構成データの再構成誤差を異常スコアとして用いることとした。

### 5. 日常生活での圧力変化値データの収集

本研究では、7名の被験者を対象として日常生活での動作を模したタスクを課し、タスク実行時の衣類型圧力センサからの圧力変化値を収集した。7名の被験者の年齢は  $24.9 \pm 2.4$  歳、性別は男性が5名、女性が2名であった。

#### 5.1 被験者に課す日常生活行動タスク

本研究の最終的なターゲットである高齢者が利用することを想定し、高齢者の要介護基準に利用される日常生活動作指標に含まれる日常生活動作を被験者に課すタスクの候補とした。高齢者の要介護基準に利用される日常生活動作指標には、バーセル指数 [11]、Lawton 尺度 [12] などがある。これらの日常生活動作指標では、食事、歩行、整容などの項目から構成され、高齢者の日常生活レベルを測定するために用いられているため、タスクの選定に好適であると考えた。日常生活動作指標を参考にし、かつ、実験室環境で再現可能な次の8つのタスクを選択した。

**歩行** 利用者の家庭内での歩行を想定した。廊下の20mほどの区間の往復を以て、歩行タスクとした。

**車椅子** 車椅子利用者の家庭内の車椅子移動や、移譲動作を想定した。車椅子移乗と、廊下の20mほどの区間の往復を以て、車椅子タスクとした。

**就寝・起床** 利用者が寝室へ向かい就寝、起床して寝室から退室する動作を想定した。扉のある別室にマットレスを設置し、そこで就寝姿勢を取る動作を以て、就寝・起床タスクとした。実験時間の制約から、就寝時間は5分程度とした。

**食事** 利用者が食事を摂る動作を想定した。実験中に実際に食事を摂ることは、実験実施時間や場所、予算の制約から難しかったため、皿から皿へ金属部品を箸で移す動作を以て食事タスクとした。

**トイレ** 利用者がトイレで用を足す動作を想定した。実際にトイレ内でタスクを行うのはプライバシーの観点から好ましくないと判断し、扉のある別室にパイプ椅子を用意し、パイプ椅子に座る動作を以て、トイレタスクとした。

**掃除** 日常生活動作指標の中でも家事に大別されるタスクとして、部屋内の掃除機がけを想定した。実験室内を掃除機がけする動作を以て、掃除タスクとした。




図 2 VAE を用いた異常検知モデルの構成

**テレビ視聴** 日常生活動作指標の中でも安静状態に大別されるタスクとして、高齢者施設内で高齢者がテレビを見て過ごすことが多いことから、部屋内でのテレビ視聴を想定した。ソファに座ってリモコン操作し、10分程度テレビを見る動作を以て、テレビ視聴タスクとした。

## 5.2 計測手順

まず、被験者は実験同意書に記入した後、実験の手順説明を受けた。手順説明では、日常生活の衣類上の圧力値を計測することが目的であることを伝えた上で、センサの破損を気にせず、できるだけ自然な動作を行うように指示した。次に、被験者は3節で詳述した衣類型圧力センサを着衣した。衣類型圧力センサの上着は被験者の肌着の上から、ズボンは被験者のズボンの上から着用することとした。被験者がソファに座るなどして、衣類上の圧力値が計測できていることを確認した後、各日常生活動作の収集を開始した。前節で挙げた8つのタスクは、ラテン方向に基づき、被験者間で異なる順序を組んだ。各タスクの境界を明確にするため、各タスク間には1分程度ソファでの安静状態を挟んだ。各タスク中の衣類上の圧力値計測後、被験者は衣類型圧力センサを脱ぎ、センサの着用感を問う事後アンケートに回答した。

## 6. 評価用の擬似衝撃データの作成

本研究の目的が未知の衝撃検知であるため、本来であれば、日常生活行動中に発生する衝撃を評価データとしたい。しかしながら、衣類型圧力センサの着衣者に衝撃を意図的に指示することは倫理上不可能であるし、また、さまざまな衝撃パターンを網羅するのも難しい。そこで、機械学習分野で学習データを水増しするために用いられるデータ拡張 (Data Augmentation) の考え方を応用し、擬似的に衝撃由来の圧力値を生成し、評価用データとして用いる方針をとる。

異常データの生成には、圧力値を圧力変化値に変換することで異なる基準値の圧力データを重ねることができるとに着目し、マネキンに着せて別撮りした衝撃データを圧力変化パターンに重ね合わせることにした。衣類の着衣者が日常生活中に物に強打したときの衝撃成分を収集すること

を目的として、実験用のマネキンに衣類を着せ、ポスターケースを用いた衝撃を与えることとした。身体の様々な箇所を強打することを想定し、衣類型圧力センサの計測領域である背面を中心に満遍なく300回分の衝撃を収集した。

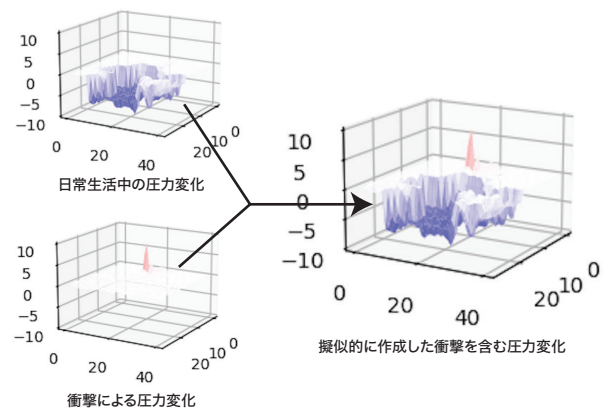


図 3 マネキンを用いて収集して作成した擬似異常データ

図3に、マネキンを用いて取得した衝撃由来の圧力変化値と、それと日常生活の圧力変化値を足した擬似異常データの例を示す。日常生活の圧力変化値に着目すると、日常生活に発生していると考えられる圧力変化値が、正・負方向にそれぞれ緩やかな山・谷として可視化される。これは着座時に背もたれに接触したり、横臥時に背中に圧力がかかることで生じていると考えられる。また、程度の小さいノイズも現れており、これらは日常生活動作によって服の皺などの状態が変化していることによるものと考えられる。日常生活の圧力変化値に対し、衝撃は鋭利な山や谷として可視化される。衝撃を受けた瞬間と衝撃を与えた物体が衣類から離れる瞬間に圧力変化値が増大するため、それらが可視化されると考えられる。以上の日常生活と衝撃時を足し合わせた圧力変化値に着目すると、日常生活の圧力変化の中に衝撃成分を加算できていることが確認できる。日常生活の圧力変化値から、この衝撃成分を検知することを目的として、提案手法を評価することができると思われる。

## 7. VAE を用いた教師なし異常検知手法の評価

本節では、4節で提案した異常検知手法の評価について

述べる。衣類型圧力センサと教師なし異常検知手法による衝撃検知への有効性の初期検討のため、異常検知率の評価に加えて、今後手法を改善していく上で有用になり得る再構成データや異常スコアの分布も評価する。

### 7.1 データの前処理・学習・評価手順

提案手法の評価のための、データの前処理、学習、評価手順について述べる。

まず、学習・評価に用いるデータの前処理について説明する。最初に、計測値のフレームレートを統一するために、スプライン補間を用いて 250ms にリサンプリングした。次に、被験者実験により収集した 7 名分のデータから、タスク遂行時のフレームのみ抽出した。基準値変動へ対処するための圧力変化値への変換処理、並びに、ZScore を用いて圧力変化値の標準正規化を施した。異常検知モデルに入力する際には、16 フレームの時間方向のスライディングウィンドウを用いて切り出した。学習・評価データの分割は一人抜け交差検証を用いた。学習用データには 6 名分の日常生活行動中の圧力変化値のみを正常データとして含めた。評価用データには 1 名分の日常生活行動中の圧力変化値を、異常検知評価時の正常・異常データの割合を均等にするため、半分を無加工のものを正常データ、残りの半分を擬似異常データとして含めた。評価用の異常データは、6 節で示した、別撮りした衝撃時の圧力変化成分を正常データに足し合わせることで擬似的に作成した。

前処理を施したデータを用いて、VAE を用いた再構成モデルを学習させた。学習率は 0.001、最大エポック数は 50 とした。5 節で、収集した日常生活の圧力変化値のみを再構成モデルに学習させた。再構成モデルの損失関数は、再構成誤差と KLD 損失の合成値とした。再構成誤差には、平均二乗誤差を用いた。VAE の正常値の再構成能力の獲得を評価するために、学習エポックごとの各損失と、評価用データを用いて算出した評価指標を追跡できるように記録した。

異常検知モデルの初期検討評価のために、再構成データ出力部と異常スコア算出部のそれぞれを評価した。再構成データ出力部の評価は、入力データと再構成データを可視化による比較と、再構成損失の変化を出力することで行った。異常スコア算出部の評価は、再構成損失を異常スコアとして算出し、正常・異常のラベルに基づいて、ROC 曲線 (Receiver Operating Characteristic Curve) の AUC (Area Under the ROC Curve) により評価した。

### 7.2 再構成データの評価

再構成データの評価のために、入力データと再構成データの可視化による比較と、再構成損失の変化を出力した。

再構成データの出力例を図 4 に示す。各プロットは、時系列の圧力変化値の行列に対して、同時刻の圧力変化値を

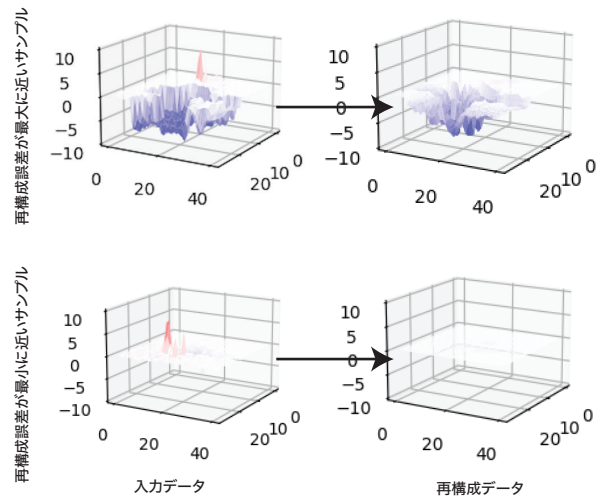


図 4 圧力変化値の入力データと再構成データの可視化

3次元空間上に可視化したものである。異常データと判断しづらいケースを観察するため、再構成誤差が最大のサンプルと最小のサンプルを出力した。

2 サンプルに共通して、衝撃成分を重ねる前に現れていた圧力変化の分布は再構成されたものの、異常である衝撃成分は、再構成データ上に現れなかった。再構成誤差が最大に近いサンプル、つまり異常データと判断されやすいサンプルは、日常生活の圧力変化成分を多く含むデータであった。一方、再構成誤差が最小に近いサンプル、つまり異常データと判断されにくいサンプルは、日常生活の圧力変化成分が少ないデータであった。




図 5 学習エポックに対する再構成損失の変化

次に、VAE の圧力変化値の再構成能力獲得状況を確認するために、学習エポックごとの再構成損失の変化を出力したグラフを図に示す。学習が進むにつれて、学習に用いていない評価用のデータに対しても、再構成損失が低下しており、VAE の再構成能力が汎化性能を獲得していることを示すものである。

### 7.3 異常スコアの評価

異常スコアの評価は、再構成損失を異常スコアとして算出し、正常・異常のラベルに基づいて、ROC 曲線 (Receiver Operating Characteristic Curve) の AUC (Area Under the Curve) により評価した。また、学習エポックごとに AUC を評価し、VAE のデータ再構成能力獲得に伴う異常検知能力の推移を観察することとした。

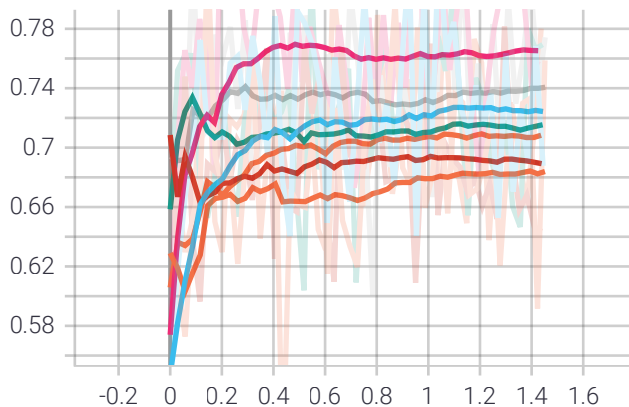


図 6 学習エポックごとの AUC の推移

異常スコアを基にした場合の学習エポックごとの AUC の推移を図 6 に示す。学習が進むにつれて、AUC 値は向上し、50 エポック終了後には AUC が  $0.718 \pm 0.029$  に達した。

## 8. 考察

7 節で述べた提案手法の評価結果から、無自覚打撲検知への応用可能性について述べる。初期検討で用いた異常検知モデルの評価結果について議論した後、本稿における研究の限界、並びに今後の展望について述べる。

本稿では、日常生活の衣類上の圧力変化値から衝撃成分を検知する課題を設定した。課題の初期検討として、正常データのみを再構成ネットワークに学習させて、異常データ入力時にうまく再構成できない特性を応用した手法を用いた。本手法の衝撃検知への応用可能性を議論するために、異常データである衝撃成分を含む圧力変化値を入力とした時の再構成データについて考察する。

図 4 の 2 サンプルに共通して、衝撃成分を重ねる前に現れていた圧力変化の分布はうまく再構成されたと考えられる。一方で、意図的に追加した衝撃成分はうまく再構成されなかったため、目論見通りだったと言える。図 5 から再構成損失が学習が進むにつれて低下していることから、正常データである日常生活の圧力変化値を学習できていると考えられる。

可視化ではうまく再構成されたように見えるものの、異常データと判断されやすいサンプル、つまり再構成誤差が大きいサンプルは、日常生活の圧力変化成分を多く含む

データであった。この原因としては、学習データに用いた圧力変化値の中で近似のデータを再構成しようとしているものの、完全に一致させることは難しく、一致しなかった箇所の差分が平均二乗誤差として大きく出力されたものと考えられる。以上の結果から、再構成モデルの改善には、学習データを足して再構成可能な正常データの種類を増やすこと、潜在空間の次元数を増やして学習できる情報量を増やすこと、再構成誤差の算出方法を再検討することが必要であると考えられる。

## 9. まとめ

受傷理由不明の打撲が認知症高齢者の介護において問題となっており、事故の発生時刻や、衝撃を受けた箇所がわかれば、受傷理由を特定するために有用である。本課題に対して、過去に我々が提案した衣類型圧力センサと VAE のデータ再構成能力を基とした教師なし異常検知手法を用いることで、無自覚打撲検知への応用可能性を先行的に検討した。

学習させる正常データとして必要な日常生活の衣類上の圧力変化パターンを収集するために、7 名の被験者を対象として圧力変化値を計測した。日常生活のデータパターンを収集するために、被験者に 8 つの日常生活タスクを課した。提案手法を評価するための衝撃データを得るために、衝撃時の圧力変化成分をマネキンを用いて別撮りし、正常データに重ね合わせることで擬似的に作成した。

異常検知モデルの初期検討評価のために、再構成データ出力部と異常スコア算出部のそれぞれを評価した。再構成データ出力部の評価で、入力データと再構成データの可視化による比較と、再構成損失の変化を出力することで行った結果、目論見通り、正常データの再構成能力を獲得しつつ、異常データである衝撃成分をうまく再構成できない様子を観察できた。異常スコア算出部の評価で、再構成損失に基づいた異常スコアと正常・異常のラベルに用いた評価の結果、学習が進むにつれて異常検知能力を獲得でき、ROC 曲線の AUC は  $0.718 \pm 0.029$  に達した。以上の結果から、VAE のデータ再構成能力を基とした教師なし異常検知手法を用いることで、無自覚打撲検知への応用可能性が示された。

再構成データを観察することにより、異常検知モデルの改善に繋がる知見も得られた。手法の改善には、学習データを足して再構成可能な正常データの種類を増やすこと、潜在空間の次元数を増やして学習できる情報量を増やすこと、再構成誤差の算出方法を再検討することが必要であると考えられる。今後の課題とする。

また、本稿で先行的に調査した衣類型圧力センサと VAE を用いた教師なし異常検知手法が無自覚打撲検知に有効であることが示されたことから、評価対象を広げたり、モデルのチューニングを行うことでより高性能にし、実用評価

に繋げたい。具体的には、衣類型圧力センサのズボン部分を用いて衝撃検知可能な範囲を広げたり、マネキンを用いて実際に転倒した時の本手法の評価を行ったり、モデルのパラメータ探索を行ったり、衝撃箇所の特定制を試みたりすることを今後の課題とする。

**謝辞** 本研究は JSPS 科研費 21H03481 の助成、ならびに、栢森情報科学振興財団の研究助成を受けたものです。

## 参考文献

- [1] 三田寺裕治, 赤澤宏平. 介護保険施設における介護事故の発生状況に関する分析. 第 30 巻, pp. 123–130. 日本社会医学会事務局, jun 2013.
- [2] Use fall detection with Apple Watch. <https://support.apple.com/en-us/HT208944> (最終アクセス: 2021/05/08).
- [3] 小野瀬良佑, 榎堀優, 間瀬健二. 褥瘡看護ケア支援に向けた体表圧を計測可能な衣類型圧力センサの研究. 情報処理学会論文誌, pp. 1827–1836, 2018.
- [4] Diederik P Kingma and Max Welling. Auto-encoding variational bayes, 2014.
- [5] 河野禎之, 山中克夫. 施設入所高齢者における転倒・転落事故の発生状況に関する調査研究. 老年社会科学, Vol. 34, No. 1, pp. 3–15, 2012.
- [6] Leila Panahi and Vahid Ghods. Human fall detection using machine vision techniques on RGB-D images. *Biomedical Signal Processing and Control*, Vol. 44, pp. 146–153, July 2018.
- [7] Bummo Koo, Jongman Kim, Taehee Kim, Haneul Jung, Yejin Nam, and Youngho Kim. Post-fall Detection Using ANN Based on Ranking Algorithms. *International Journal of Precision Engineering and Manufacturing*, Vol. 21, No. 10, pp. 1985–1995, October 2020.
- [8] Paul Bergmann, Kilian Batzner, Michael Fauser, David Sattlegger, and Carsten Steger. The MVTEC Anomaly Detection Dataset: A Comprehensive Real-World Dataset for Unsupervised Anomaly Detection. *International Journal of Computer Vision*, Vol. 129, No. 4, pp. 1038–1059, April 2021.
- [9] Aaron van den Oord, Oriol Vinyals, and koray kavukcuoglu. Neural discrete representation learning, 2017.
- [10] Yu Enokibori, Akihisa Suzuki, Hirotaka Mizuno, Yuuki Shimakami, and Kenji Mase. E-textile pressure sensor based on conductive fiber and its structure. In *Proceedings of the 2013 ACM Conference on Pervasive and Ubiquitous Computing Adjunct Publication*, UbiComp '13 Adjunct, pp. 207–210, New York, NY, USA, 2013. ACM.
- [11] F. I. Mahoney. Functional evaluation: the barthel index. *Maryland State Medical Journal*, Vol. 14, pp. 61–65, 1965.
- [12] MP Lawton and EM Brody. Instrumental activities of daily living scale (iadl). *Gerontologist*, Vol. 9, pp. 179–186, 1969.