

フィジカルフレイル診断支援のための
歩行時 3 軸加速度データを用いた CNN による低筋力状態検出
Detection of Low Muscle Strength by CNN Using 3-Axis Acceleration Data
during Walking toward Physical Frailty Diagnosis Support

中村 早希[†] 増尾 明[‡] 竹尾 淳^{†§}// 佐久間 拓人[†] 加藤 昇平[†]
渡邊 航平[⊥] 川出 義浩^{//} 間辺 利江^{//} 赤津 裕康^{//}
Saki Nakamura Akira Masuo Jun Takeo Takuto Sakuma Shohei Kato
Kohei Watanabe Yoshihiro Kawade Toshie Manabe Hiroyasu Akatsu

1. はじめに

世界的に急激な高齢化が進んでいる。2020 年の国際連合の報告^[1]では、2020 年に 65 歳以上の高齢者は世界人口の 9.3 % に該当する 7 億 2700 万人と推計される。また、2050 年には世界人口の約 16.0 % の 15 億人に到達すると予測され、加齢による身体機能の虚弱を示す身体的フレイルの予防が喫緊の社会課題となっている。

身体的フレイルは、加齢により筋力低下し、歩行のみならず日常生活に影響をもたらす状態を指す。Koyama ら^[2]は、内科疾患による入院患者を対象とした研究において、Kihon Checklist を用いて評価された入院時の身体的フレイルと、退院 1 ヶ月までの要介護・要支援認定リスクとの関係を調査した。その結果、フレイル患者は健常者と比べ、認定リスクを有意に高めることを報告している。したがって、人々が自立した日常生活を送る期間である健康寿命の延伸のためには、フレイルの予防・早期発見が重要である。

身体的フレイルの国際的な指標には、Cardiovascular Health Study 基準 (CHS 基準)^[3]が用いられるが、日本人の体格に合った指標ではないことから、的確な診断が困難であるとされている。そのため、厚生労働省が介護予防のために作成した Kihon Checklist を取り入れ、2020 年に Satake ら^[4]は、日本で用いられる簡易的な指標として日本語版フレイル基準 (J-CHS 基準) を改訂した。本基準では体重減少、筋力低下、疲労感、歩行速度、身体活動から構成される 5 つの評価項目に対して 3 項目以上に該当した場合をフレイル、1-2 項目に該当した場合をフレイルの予備群とするプレフレイル、該当しない場合を健常状態であるロバストと定義している。

しかしながら、身体的フレイルの診断基準である J-CHS 基準の指標の 1 つとして握力が挙げられるが、握力計は一般家庭に普及しておらず、握力の測定には体育施設や病院等の施設で扱っている専門的な機器で測定する必要があり、握力の日常的な測定が可能な体制は整っていないのが現状である。また、池田ら^[5]は地域在住女性高齢者を対象に下肢筋力や歩行機能、平衡機能などの身体機能評価と握力との関連を調べた。その結果、握力は上肢筋力のみならず、下肢筋力や立位バランス、応用歩行能力を反映しているこ

表 1 歩行トレーニング実施前の参加者の基本属性

項目	予備群 (n=5)	健常群 (n=20)
年齢 (歳)	78.8 [73 - 89]	68.1 [51 - 78]
左右の握力の 平均値の平均値 (kg)	16.96 [15.9 - 17.8]	23.93 [19.8 - 30.0]
身長 (cm)	145.46 [135.3 - 156.4]	155.65 [144.5 - 166.8]
右脚の最大 下肢周長 (cm)	32.74 [29.4 - 35.7]	34.24 [31.0 - 39.4]
左脚の最大 下肢周長 (cm)	33.14 [29.1 - 35.4]	34.44 [31.0 - 39.9]

平均値 [最小値 - 最大値]

とを報告しており、握力低下と全身性の筋力低下との関連が示唆されている。

したがって、本稿では身体的フレイルの診断基準の筋力低下の項目である握力に着目し、加速度データを使用した身体的フレイルのリスク要因である低筋力状態の推定を目的とした。低筋力状態の者および健常者を対象に、歩行トレーニング時の加速度データを 1 歩行周期長で取り出した。加速度データを画像化し、深層学習アルゴリズムへの入力とすることで、画像認識技術の特徴抽出に活用した低筋力状態の識別性能を評価した。日常生活で実施した歩行トレーニング時の加速度データから、低筋力状態を簡易的に評価することで、下肢筋力が低下した中高齢者に対して筋力増強のためにトレーニングを促すことができ、中高齢者の健康寿命の延伸への寄与が期待できる。

2. 方法

2.1 対象

本研究では、Akatsu ら^[6]が測定したデータを使用した。ポスターなどで地域、企業、行政職員、施設入所者等への呼びかけを実施し、集まった参加者を対象とした。参加者は関節痛、筋肉痛、自発痛や運動痛がない者とした。河西^[7]は高齢者の体力を 14 点満点で評価する Motor Fitness Scale (MFS) の得点率が 8 点以下と 9 点以上の者とは転倒率に有意差があると報告している。よって、本研究では自立した日常生活を送ることができ、MFS の得点が 9 点以上を満了者を対象とした。また、性別による運動機能の違いを想定し女性のみを対象とした。したがって、本研究では 25 名 (平均年齢 70.92 歳) のデータを用いた。参加者は、日本のフレイルの診断の指標として用いられる J-CHS

[†] 名古屋工業大学 Nagoya Institute of Technology

[‡] 修文大学 Shubun University

[§] 名古屋国際工科専門職大学 International Professional University of Technology in Nagoya

// 名古屋市立大学 Nagoya City University

⊥ 中京大学 Chukyo University

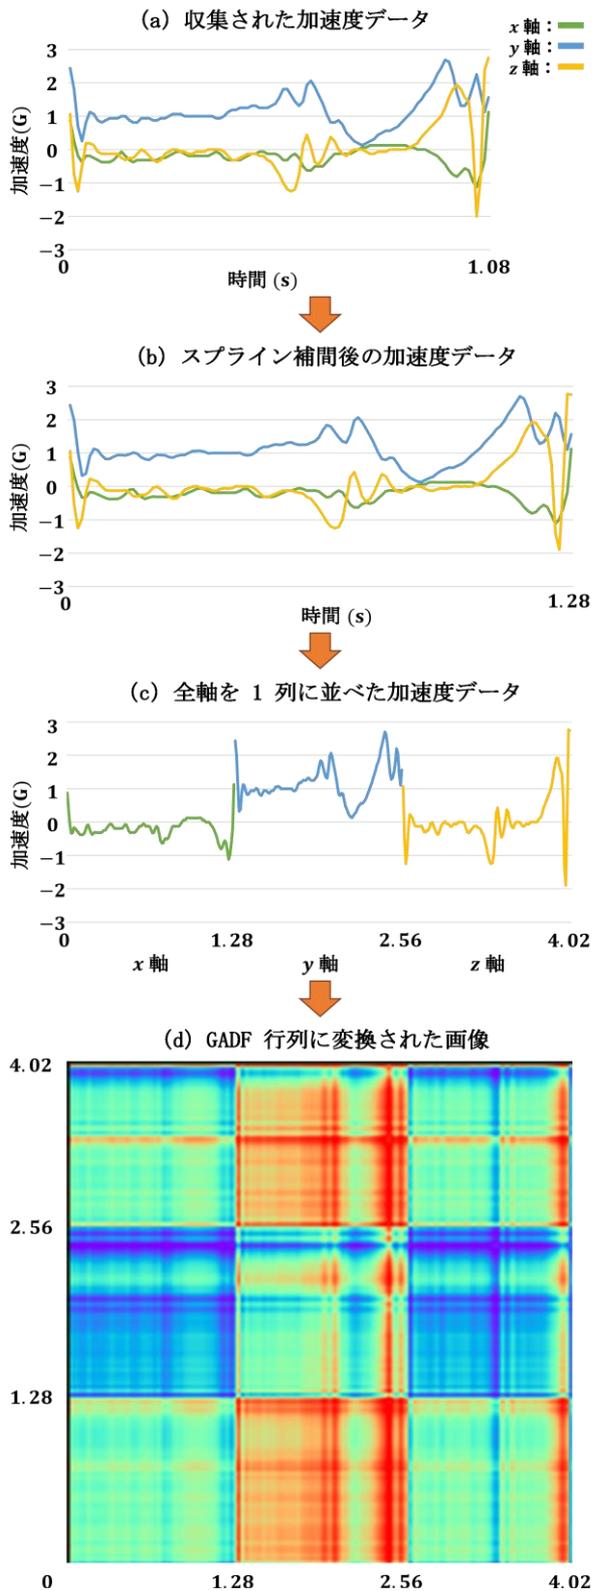


図 1 前処理と画像化の概要

基準^[4]の筋力低下の項目から、握力の閾値を 18 kg とし、本研究では左右の握力の平均値を握力の指標として使用した。歩行トレーニング実施前に測定した握力のスコアが 18 kg 未満の参加者を「予備群」として 5 名（平均年齢 78.80 歳）、18 kg 以上の参加者を「健常群」として 20 名

（平均年齢 68.95 歳）の判別評価を実施した。表 1 に介入前測定会での基本属性の平均スコアを示す。参加者の握力の平均は 22.54 kg であり、「予備群」の握力の平均は 16.96 kg、「健常群」の握力の平均は 23.93 kg であった。なお、本研究では 2 群の参加者数に差があるため、健常群から無作為に 5 名を抽出した。n = 10 名の測定データを用いて識別モデルの構築と識別性能を検証する。

2.2 使用機器

加速度データの測定には 3 軸加速度センサー「Axivity 社製 AX3」を用いた。本デバイスのサイズは縦 23 mm、横 32.5 mm、高さ 7.6 mm、重量は 11 g であり、サンプリング周波数は 100 Hz で前後・側方・垂直方向の加速度を計測可能である。センサーは x 軸を側方方向、y 軸を垂直方向、z 軸を前後方向になるように装着した。Akatsu ら^[6]は歩行トレーニングで使用する重錘の理想的な重量は体重の 2 % であると報告していることから、重錘の重量を片脚あたり 0.5 kg、0.8 kg、1.0 kg、1.5 kg の重量の候補群から体重の 2 % に最も近い重量に選択した。参加者が選択した重錘を 5 分以上装着し、「歩行トレーニングに適した、負荷を感じ、かつ無理のない程度の重量」であるか確認した後に、担当主治医の判断によって決定した。この条件を満たさない場合は他候補の重量へ変更した。最終的に選択した重量を参加者の同意および自己責任のもとで使用した。

2.3 歩行加速度データの計測

センサーの装着部位は両下腿遠位部中央とし、重錘はセンサー表面を覆うように両下腿に装着した。本研究では、歩行トレーニングを開始する前に握力をはじめとする身体機能評価を実施した。歩行トレーニング開始直後から 3 回分の屋外歩行を解析対象とした。なお、歩行トレーニングとは、筋力増強を目的とした重錘負荷を用いたレジスタンス歩行によるトレーニングのことである。運動時は重錘を両下腿に負荷し、頻度は週 2 回、運動負荷量は 1 回 20 分以上の条件として、参加者各自が歩行トレーニングに適した歩行速度・時間帯・屋外歩行環境を設定し、歩行トレーニングを実施した。実際の歩行トレーニング時の加速度データを使用し、実環境のデータによりフレイルの傾向を定量的に評価することとしている。

2.4 データセットの構築

図 1 に参加者 1 名から取得したデータ例および前処理と画像化の概要を示す。計測したデータのうち、20 分以上の歩行トレーニングを実施しているデータからヒューリスティックに歩行トレーニング初期の初期から 1 歩分を抽出し、3 歩分を解析対象とした。また、本研究では歩行動作の左右対称性から、左足首の加速度データを使用している。1 歩分は歩行トレーニング時に得られた加速度の波形のデータのセグメントを目視で確認した（図 1 (a) 参照）。これらのデータを歩行トレーニング介入初日から 3 日分抽出した。したがって、本研究では 1 人あたり 9 サンプルを抽出した。計測した加速度データは長さが異なることから、データ間の長さが均等になるように、3 次スプライン補間を用いることで、データの時間長を 1.28 秒（27 サンプル）に統制した（図 1 (b) 参照）。

本研究では、加速度データを画像化するため、Gramian

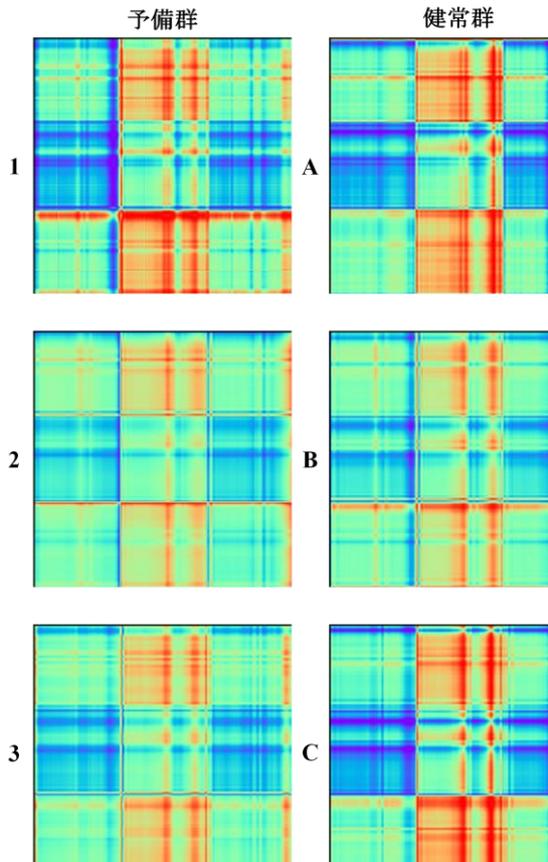


図 2 生成された画像の一例

Angular Difference Field (GADF)^[8]を用いた。サンプルを x 軸方向、y 軸方向、z 軸方向の順に結合し、サンプルを $[-1, 1]$ に再スケールした後に、データの時間的関係を保持した状態の行列を生成した (図 1 (c) 参照)。生成された行列から解像度 217×217 のカラー画像を出力した (図 1 (d) 参照)。図 2 に「予備群」の参加者 1, 2, 3 および「健常群」の参加者 A, B, C の 3 名の参加者の 1 歩分の加速度データから作成した画像を示す。画像を畳み込みニューラルネットワーク (CNN : Convolutional Neural Network) の入力データとし、CNN の結果を特徴量とするデータセットを構築した。

また、J-CHS 基準^[4]の歩行速度の項目から、歩行周期特徴を特徴量に加えた。抽出された加速度データの周期長から、統制した長さである 1.28 秒を取り除いた値を特徴量としている。したがって、本研究では加速度データから生成された画像を入力とする CNN の推定確率、および歩行周期特徴を特徴量を持つデータセットを構築した。

2.5 モデルの構築と識別性能評価

図 3 に本研究で構築した低筋力状態検出モデルの概要を示す。前述の特徴量抽出および「予備群」の推定確率に CNN を使い、推定確率と歩行周期特徴を用いた分類モデルに SVM を用いた。CNN はテストデータとして、各群 1 名ずつの歩行データを無作為に取り出し、残りの参加者のデータ (予備群 : 4 名、健常群 : 19 名) を CNN の学習に使用した。CNN モデルの構成には出力データサイズ (縦×横×カーネル数) が示されている。全てゼロパディ

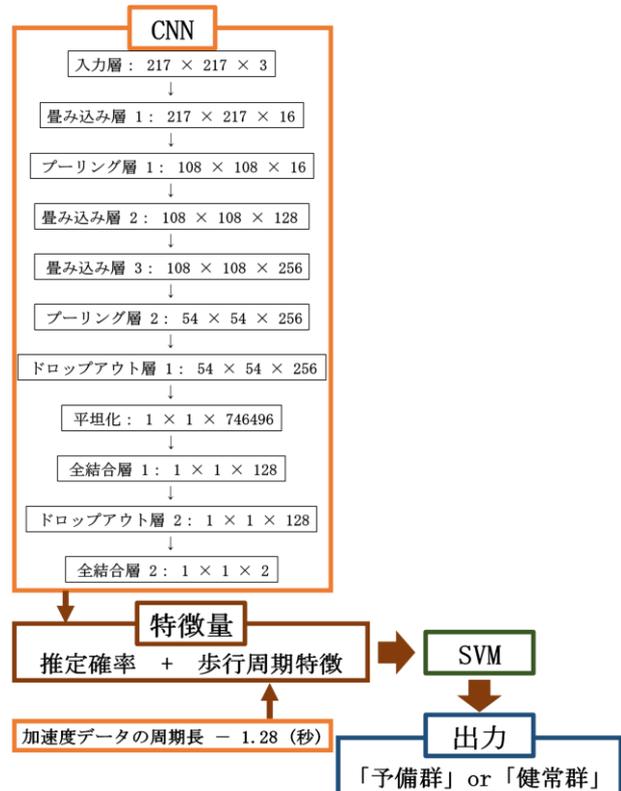


図 3 低筋力状態検出モデルの概要

ングとし、ストライドの大きさは畳み込み層で 1、プーリング層では 2 とした。また、プーリング層では max pooling を施し、全ての畳み込み層および全結合層 1 の活性化関数には ReLU 関数を用いて、出力は「予備群」の推定確率としている。ネットワークの学習には、損失関数に交差エントロピー、最適化に Adam、評価関数に正答率を使用した。ネットワークの学習には確率的勾配法を使用し、学習セットと検証セットに 3:1 の割合で分割し、エポック数は 40 とした。本研究は CNN の構成に使用する参加者数が「予備群」4 名と「健常群」19 名と差があることから、偏りを無くすため、両群の学習データにノイズを付与し、データ拡張を実施した。生成した画像にガウシアンノイズを付与し、ノイズ画像を生成した。ノイズの平均値 μ は $[-5, 5]$ 、標準偏差 σ は $[0, 10]$ のスケールからランダムに設定した。「予備群」は 1 つのサンプルにつき、9 枚のノイズ画像を生成し、元の画像と併せて 360 枚の画像を CNN の構成に使用するサンプルとし、「健常群」は 1 つのサンプルにつき、1 枚のノイズ画像を生成し、元の画像と併せて 342 枚の画像をサンプルとしている。CNN の構成に使用するデータとして、各群から 300 枚を無作為に抽出し、600 枚を使用した。このモデルを 5 つ作成し、それぞれのテストデータの結果を特徴量とした。

また、SVM の学習はカーネルとして Gaussian カーネルを、ハイパーパラメーター C は 0.1, 0.11, 0.12, ..., 0.99, 1、 γ は 0.01, 0.02, 0.03, ..., 0.99, 1 と使用した。本研究では、5 分割交差検証法による分類性能評価を実施した。正答率、適合率、再現率、F1 スコアを求め、SVM の各検証の平均値を評価指標とした。

		予測値	
		予備群	健常群
実測値	予備群	34	11
	健常群	3	42

図 4 混同行列 (n = 10, 90 サンプル)

表 2 識別性能 (平均値 ± 標準偏差)

	CNN のみ	提案モデル
正答率	0.79 ± 0.15	0.84 ± 0.16
適合率	0.83 ± 0.15	0.95 ± 0.10
再現率	0.82 ± 0.36	0.76 ± 0.35
F1 スコア	0.74 ± 0.28	0.77 ± 0.30

3. 結果

図 4 に低筋力状態検出モデルの混同行列を示す。また、表 2 に CNN および低筋力状態検出モデルの識別性能を示す。「予備群」と「健常群」の識別正答率は 84 %、適合率は 95 %、再現率は 76 %、F1 スコアが 77 %であった。

4. 考察

識別性能として提案モデルの正答率は 84 %であった。先行研究^[9]では、歩行時の時間領域特徴量と周波数領域特徴量を抽出し、握力低下状態の識別性能を評価した結果、識別正答率は 82 %であった。また、CNN のみの正答率は 79 %であった。この結果から歩行時の加速度データを画像化することで、中高齢者の身体的フレイルを検知できる可能性が高まることが示唆された。GAF を用いることで先行研究では抽出できなかった加速度の時間的変化を取り入れたと考える。本研究の結果は先行研究よりも高い正答率であったが、改善の余地はあると考える。Arshad ら^[10]は、高齢者の歩行信号を GAF により生成した連続する 3 歩の画像を入力とする CNN モデルを用いて、高齢者の虚弱状態を推定した結果、85 %の正答率で分類することができたことを報告している。本研究では 1 歩分の画像を入力していることから、歩容間の変動や各歩容の特徴が反映されていない可能性がある。連続する数歩分の歩行データを入力とすることで、本研究で抽出されていない特徴を捉えることができ、識別性能を向上させることができると考える。

また、低筋力状態のスクリーニングを目的とするためには再現率を向上させる必要がある。提案モデルの再現率が 76 %であり、先行研究の再現率は 75 %であったことから、再現率の向上も確認できた。しかし、CNN のみの再現率 82 %よりも低下していることから、より再現率を重視した分類モデルの学習を考える。

5. おわりに

本研究では、中高齢者を対象に歩行トレーニング時に収集された 3 軸加速度データを用いて、身体的フレイルの診断基準である低筋力状態の検出を目的とした。収集されたデータを画像化し、CNN の入力とすることで得られた推

定確率とともに、歩行周期特徴を特徴量とする提案モデルの結果、識別正答率は 84 %であり、画像化された加速度データを用いて低筋力状態を検出することができる可能性が示唆された。

本研究では重錘を負荷した歩行トレーニングが適応可能な者を対象としているため、「予備群」に該当する参加者が少なかった。また、対象群間で大きな年齢差がある。今後、参加者を増やし、年齢差の減少を図るとともに、有用な特徴量の調査ならびに識別性能の向上させる必要がある。また、通常歩行時のデータを収集し、歩くだけで身体的フレイル状態が否かを検出する応用例の実装を検討することで、中高齢者の健康寿命延伸を目的とした身体的フレイルの早期検出を支援し、高齢者福祉分野への貢献を目指す。

謝辞

本研究にご協力いただいた参加者の皆様、および本研究にご尽力くださった関係者、加速度センサーおよび重錘を提供いただいたジーワン(株)に心より感謝申し上げます。

本研究は、一部、文科省科研費 (JP19H01137、JP19H04025、および JP20H04018) により実施された。

参考文献

- [1] United Nations: Ageing 2020 Highlights: Living arrangements of older persons (ST/ESA/SER.A/451), United Nations Department of Economic and Social Affairs, Population Division (2020).
- [2] S. Koyama, H. Katata, D. Ishiyama, T. Komatsu, J. Fujimoto, M. Suzuki, M. Yamada, and M. Yamatoku: "Preadmission frailty status as a powerful predictor of dependency after discharge among hospitalized older patients: A clinical - based prospective study", *Geriatrics & Gerontology International*, Vol.18, No.12, pp.1609-1613 (2018).
- [3] L. P. Fried, C. M. Tangen, J. Walston, A. B. Newman, C. Hirsch, J. Gottdiener, T. Seeman, R. Tracy, W. J. Kop, G. Burke, and M. A. McBurnie: "Frailty in older adults: Evidence for a phenotype", *The Journals of Gerontology Series A: Biological Sciences and Medical Sciences*, Vol.56, No.3, pp.M146-M157 (2001).
- [4] S. Satake and H. Arai: "The revised Japanese version of the Cardiovascular Health Study criteria (revised J-CHS criteria)", *Geriatrics & Gerontology International*, Vol.20, No.10, pp.992-993 (2020).
- [5] 池田 望, 村田 伸, 大田尾 浩, 村田 潤, 堀江 淳, 溝田 勝彦, "地域在住女性高齢者の握力と身体機能との関係", *理学療法科学*, Vol.26, No.2, pp.255-258 (2010).
- [6] H. Akatsu, T. Manabe, Y. Kawade, Y. Masaki, S. Hoshino, T. Jo, S. Kobayashi, T. Hayakawa, and H. Ohara: "Effect of Ankle Weights as a Frailty Prevention Strategy in the Community-Dwelling Elderly: A Preliminary Report", *International Journal of Environmental Research and Public Health*, Vol.19, No.12, pp.7350 (2022).
- [7] 河西 敏幸, 伊藤 弓月, 工藤 大地, 本田 春彦, 植木 章三, 高戸 仁郎, 犬塚 剛, 永富 良一, 芳賀 博, "都市部高齢者における高齢推進リーダーを中核とした転倒予防プログラムの開発と評価", *障害者スポーツ科学*, Vol.5, No.1, pp.18-31 (2007).
- [8] Z. Wang, T. Oates: "Imaging Time-Series to Improve Classification and Imputation", *Proceedings of the Twenty-Fourth International Joint Conference on Artificial Intelligence (IJCAI 2015)*, arXiv preprint arXiv:1506.00327, pp. 3939-3945 (2015).
- [9] 中村 早希, 増尾 明, 竹尾 淳, 佐久間 拓人, 加藤 昇平, 渡邊 航平, 川出 義浩, 間辺 利江, 赤津 裕康, "3 軸加速度センサーによる歩行特徴量を用いた中・高齢者の身体的虚弱状態検出", *電気学会論文誌 C (電気・情報・システム部門誌)*, Vol.142, No.12 (2022).
- [10] M. Z. Arshad, D. Jung, M. Park, H. Shin, J. Kim, and K. R. Mun: "Gait-based Frailty Assessment using Image Representation of IMU Signals and Deep CNN", *2021 43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, pp.1874-1879 (2021).