

VR-IADL における動作プリミティブのセグメンテーション法 に関する基礎的研究

安藤泰生¹ 小濱徳人¹ Tania Giovannetti² 坂本麻衣子³ 山口武彦¹

概要: 近年, Virtual Reality (VR) 技術を医療分野へ応用する研究が注目を集めている. 我々はこれまでに VR 技術を用いて IADL (手段的日常生活活動) を評価するシステムである Virtual Kitchen Challenge (VKC) の開発を行ってきた. 先行研究では VKC 中の動作の最小単位である動作プリミティブに着目し, 動作プリミティブ毎にセグメンテーションする研究が行われてきた. 本研究では, VKC 中の被験者の指の動きを計測し得られた時系列データから二段階のプロセスを行い, 効率的に動作プリミティブ毎にセグメンテーションする手法を提案する. 評価結果より, 91.1%と高い精度でセグメンテーション可能となった. カテゴリ別では正しいセグメントの感度は 90.6%, 誤ったセグメントの感度は 91.7%となった.

キーワード: 手段的日常生活活動, Virtual Reality, 二点間到達運動

A Basic Study on Segmentation of Motion Primitives in VR-IADL

TAISEI ANDO^{†1} NORITO KOHAMA^{†1} TANIA GIOVANNETTI^{‡2}
MAIKO SAKAMOTO^{‡3} TAKEHIKO YAMAGUCHI^{†1}

Abstract: In recent years, research on the application of Virtual Reality(VR) technology to the medical field has been getting a lot of attention. We have developed the Virtual Kitchen Challenge(VKC), a system to evaluate IADL(Instrumental Activities of Daily Living) using VR technology. Previous studies have focused on motion primitives, which are the smallest unit of motion in VKC, and segmented them by motion primitives. In this paper, we propose a two step process for efficient segmentation of motion primitives in VKC, based on the time series data obtained by measuring finger movements during VKC. The result showed that the accuracy of the segmentation was 91.1%. By category, the sensitivity of the correct segment was 90.6% and the sensitivity of the incorrect segment was 91.7%.

Keywords: Instrumental activities of daily living, Virtual Reality, Reaching movement between two points

1. はじめに

現在, 日本では少子高齢化により高齢者人口が増えており, 2019 年の時点で 65 歳以上の高齢者人口は 3588 万人と全体の 28.4%を占めている[1]. 高齢化の進展に伴い, 認知症者とその前駆段階と定義されている軽度認知障害 (MCI: Mild Cognitive Impairment) のある高齢者の人数が増加しており, 2012 年時点で認知症者数は 462 万人と推計されている[2]. MCI に関しては, 罹患率が 65 歳以上の 10-20%との報告がある[3]ことから, 多く見積もるとわが国に MCI は 717 万人いると推定される. これは 2012 年時点の認知症者数の約 1.5 倍の人数である. これほどまでに多くの認知症者と MCI が存在するのにも関わらず, 認知症に対する根本的な治療法が確立されていないのが現状である. このような状況において重要視されているのが MCI の早期発見である. MCI は早期発見と適切な再治療により, 14-44%は正

常な状態に戻ることが報告されている[4]. そのため, MCI を早期発見するためのスクリーニング方法の確立が求められている.

近年, 手段的日常生活活動 (IADL: Instrumental Activities of Daily Living) において, MCI は健常高齢者に比べて機能低下が見られることが明らかにされている[5]. IADL とは食事の準備, 買い物, 掃除などの活動のことを指す. そこで我々は, IADL 能力を評価するためのシステムとして Virtual Reality (VR) 技術を用いた IADL のアセスメントツールである Virtual Kitchen Challenge (VKC) の構築を行ってきた[6]. VKC には Lunchbox Task と Toast & Coffee Task があり, それぞれ昼食や朝食の準備を再現したタスクとなっている. タスクには関係のない妨害刺激も存在する. VKC は IADL タスクをタブレット PC 上に構成したものであり, IADL タスクにおける物を動かす, 蓋を開けるといったインタラクションが VKC ではドラッグ, タッチといっ

1 公立諏訪東京理科大学
Suwa University of Science
2 Temple University
Temple University
3 佐賀大学
Saga University

たインタラクションになる。

先行研究で MCI をスクリーニングするための方法として、IADL タスク中のヒューマンエラーを用いる方法が有効であると明らかにされている[7]。我々の研究グループはこれまで、IADL タスク中のヒューマンエラーの中でも人間の行動の僅かな淀みである Micro-error (ME) に着目した研究や[8]、VKC 中の刺激をタッチやドラッグといった動作頻度に着目した研究[9][10]を行ってきた。ME に着目した研究においては IADL タスク中の ME の発生頻度の違いから MCI をスクリーニングできることが明らかにされている[7]。ME には、刺激に触れようとしてやめる、刺激に触れて何もせずに離す、目的やタスクの効率をあげることは関係なく、刺激を持ち上げたり動かしたりするなどがある。動作頻度に着目した研究[10]では、VKC 中の動作の最小単位である動作プリミティブに着目し、頻度データを求め頻度データに対してトピックモデル (LDA : Latent Dirichlet Allocation) を用いてクラスタリングを行った。その結果、健常大学生と MCI はそれぞれ独立したトピックに分けられた。また健常高齢者は健常大学生と MCI の特徴を持つことが示唆された。この研究により、VKC 中の動作プリミティブの頻度解析の観点からも MCI をスクリーニングできる可能性が示唆された。しかしながら、先行研究では動作プリミティブの分類を観察者が手動で動画解析をしながら行っていたために、観察者の主観が結果に影響を与えている可能性があった[10]。そのため、自動的に動作プリミティブを分類することを目的としたモデルが岩下らによって開発された[11]。具体的には、VKC における被験者の指先の位置データから得られた指先の速度と y 座標の時系列データを動作プリミティブ毎にセグメンテーションをし、セグメンテーションされたセグメント区間に対して動作プリミティブを定義した。岩下らは VKC 中の動作プリミティブとして、(1) ポインティング (2) 静止 (3) クリックまたはリリース (4) ドラッグの 4 つを定義し、VKC 中の動きはこれら 4 つの動きの組み合わせで表現できると考えた。動作プリミティブ毎にセグメンテーションされたセグメント区間ごとに速度の平均、分散などの特徴量をアンサンブル学習を用いてモデル化を行った。その結果、高精度に動作プリミティブを識別可能となった[11]。

2. セグメンテーションに関する先行研究の問題点

VKC 中の動きはタッチ、ドラッグ、ポインティングの連続であるため、動作プリミティブ単位で考えると二点間到達運動の連続であると考えられる。岩下らの研究では、2 段階のプロセスで動作プリミティブ毎にセグメンテーションする手法を提案している。具体的には、1 段階目のフェーズにおいて、得られた時系列データを加速度のゼロ交差点でセグメンテーションし、2 段階目のフェーズ

において加速度のゼロ交差点で得られたセグメント点に対して機械学習を用いて正しいセグメントか否かを識別し、誤ったセグメンテーションを消去する処理を行っている。その結果として、高精度にセグメンテーション可能となった。しかし、実験参加者が大学生のみであったために健常高齢者や MCI の動きの特性を考慮したモデルになっていない。実際、予備研究として岩下らの提案手法を用いて高齢者のデータをセグメンテーションしたところ精度が 99.4% から 64.0% に低下したことを確認した。従って本研究では、高齢者の動きの特性を考慮した新たなセグメンテーション法に関するモデルを開発することを目的とする。

3. 研究方法

本研究では、Giovannetti らの研究により得られたデータセットを用いた[12]。得られたデータは、被験者の指先の 3 次元位置と時間および動画である。本研究では、速度の時系列データから動作プリミティブ毎にセグメンテーション可能なモデルを開発することを目的とした。

3.1 被験者

Giovannetti らの研究で得られたデータの内 7 名のデータを用いた。内訳は、大学生 4 名、健常高齢者 1 名、MCI 2 名である。全員女性であり、平均年齢は 48.4 歳 (SD=33.7) であった。

3.2 VKC の Lunchbox Task

本研究で使用した Lunchbox Task には、サンドイッチ、水筒、クッキーを準備して Lunchbox に入れるメインタスクとそれぞれのメインタスクを達成するために必要なサブタスクがある。以下にメインタスクとサブタスクの詳細を示す。サンドイッチタスクでは以下の 8 つのサブタスクから構成される。

- (1) パンを 1 枚アルミホイルの上に置く。
- (2) ピーナッツジャムの蓋を開ける。
- (3) ピーナッツジャムをナイフですくってパンに塗る。
- (4) ブルーベリージャムの蓋を開ける。
- (5) ブルーベリージャムをナイフですくってパンに塗る。
- (6) もう 1 枚のパンで挟む。
- (7) アルミホイルでパンを包む。
- (8) 包んだパンを Lunchbox に入れる。

水筒タスクでは以下の 5 つのサブタスクから構成される。

- (1) ジュースの蓋を開ける。
- (2) ジュースを水筒に注ぐ。
- (3) 水筒の内蓋を閉める。
- (4) 水筒の外蓋を閉める。
- (5) 水筒を Lunchbox に入れる。

クッキータスクでは以下の 3 つのサブタスクから構成される。

- (1) 3 枚のクッキーをアルミホイルの上に置く。

- (2) アルミホイルで3枚のクッキーを包む.
- (3) 包んだクッキーを Lunchbox に入れる.

3 つのメインタスクが終了した後に Lunchbox の蓋を閉じて画面右上にある Quit ボタンを押して終了となる。

Lunchbox Task のスクリーンショットを図 1 に示す.



図 1 Lunchbox Task のスクリーンショット

Figure 1 Screen shot of Lunchbox Task.

3.3 二点間到達運動基準のセグメンテーションにおける問題点

VKC 中の動きは二点間到達運動の連続であると考えられる。二点間到達運動を行っている時は理想的には移動開始地点と終了時点は静止していることからベル型の波形になる。二点間到達運動の基準でセグメンテーションすると図2のようにセグメンテーションをすることができる。




図 2 二点間到達運動に従って動いている時の
セグメント区間

Figure 2 Segment section when moving according to a two-point reaching movement.

しかし、VKC 中の動きは実際二点間到達運動ではモデル化できない動きも含まれている．例えば、ゆっくり対象の刺激に向かって動いているような動きの場合は、図 3 のよ

うにセグメンテーションが行われてしまうということがある.




図 3 二点間到達運動に従っていない場合の
セグメント区間

Figure 3 Segment section when not following a two-point reaching movement.

3.4 提案手法

先行研究で定義した動作プリミティブでは説明できない動きとして、指を微小に動かしながら迷っている動きが挙げられる。我々はこの動きをワンダリングと名付けた。ワンダリングは、次の行動を決めるまでの思考時間中に発生することが考えられる。ワンダリングは健常大学生に比べて、健常高齢者と MCI に多く見られた。これは、健常大学生に比べ健常高齢者や MCI の方が認知機能の低下が見られ、判断速度が低下するためであると考ええる。ワンダリングかポインティングかを判断するため、我々は 1 フレームずつの動きの方向ベクトルに着目した。VKC 中においてポインティングしている時の方向ベクトルは一方向に向き、ワンダリングしている時の方向ベクトルは一方向に定まらず、進むべき方向以外にばらついた。つまり、これらの挙動は角度統計量の観点から特徴化できるのではないかと考えフォン・ミーゼス分布に着目した。

フォン・ミーゼス分布には、平均 μ と集中度 κ ($\kappa \geq 0$) の 2 つのパラメータがある。確率変数は角度 θ ($0 \leq \theta < 2\pi$ もしくは $-\pi \leq \theta < \pi$) である。集中度が大きいかほど尖った分布となる。フォン・ミーゼス分布の特性からポインティングしている時は集中度が大きく、ワンダリングの時は集中度が小さくなるのではないかと考えた。そのため、フォン・ミーゼス分布を用いることはポインティングとワンダリングかを判断するために必要と考えた。ポインティング時のフォン・ミーゼス分布とワンダリング時のフォン・ミーゼス分布をそれぞれ図 4, 5 に示す。図 4, 5 において点線の矢印は方向ベクトルであり、実線の矢印は平均ベクトルを表している。




図 4 ポインティング時のフォン・ミーゼス分布
Figure 4 Von Mises distribution during pointing.




図 5 ワンダリング時のフォン・ミーゼス分布
Figure 5 Von Mises distribution during wandering.

本研究では、岩下らの手法[11]と同様に、動作プリミティブ毎にセグメンテーションする手法を提案する。まず、1段階目では VKC 中の動作は二点間到達運動の連続であるから二点間到達運動の基準でセグメンテーションすることを考える。具体的には、二点間到達運動においては動作の開始点と終了点では速度と加速度が 0 になると考え、加速度のゼロ交差点でセグメンテーションする。加速度のゼロ交差点は、ある加速度点とその一つ前の加速度点の乗算から求めた。先に述べたように、動画では一連の動きと見えても、動作の途中で不自然なセグメンテーションされてしまう問題があった。そのため、本研究では加速度のゼロ交差点から得られる各セグメント点に対して、正しいセグメント点であるかどうかを機械学習を用いて識別し、誤ったセグメントを消去する処理を行った。セグメンテーションのアルゴリズムを図 6 に示す。




図 6 セグメンテーションのアルゴリズム
Figure 6 Algorithm of segmentation.

3.5 データセット

機械学習に学習させるための特徴量を算出する前処理として、まず初めにそれぞれの被験者の動きをスクリーン内とスクリーン外の動き、スクリーンにタッチしているセグメント区間とタッチしていないセグメント区間の動きに分けた。図 7 の時系列データにおいて点線の矩形波はタッチしているかどうかを示しており、タッチしていれば立ち上がりっておりタッチしていないと 0 になっている。タッチ終了時、つまり立ち上がりから 0 になる部分においては、図 7 に示すようにタッチ終了時の速度 V_{touch} とセグメント区間の速度の最大値 V_{max} の関係に着目した。つまりタッチ終了時の速度が速度の最大値の 10%以上が成り立つ時はそのセグメント区間はタッチ区間と見なさなかった。スクリーン外の動きのセグメント区間に対しては特徴量の算出は行わず、スクリーン内の動きのセグメント区間に対してのみ特徴量の算出を行ってデータセットを作成した。特徴量は、セグメント区間の時間、セグメント区間の速度の最大値、セグメント区間の速度の最大値に対するセグメント時の速度の割合、セグメント区間のタッチの有無、次のセグメント区間のタッチの有無、フォン・ミーゼス分布における κ の時間的分散の 6 つである。データセット数の合計は 1581 個となった。




図 7 前処理に関わるタッチデータと速度波形
Figure 7 Pre-processing touch data and velocity profile.

4. 実験結果・考察

データセットから決定木を用いてモデル化を行った結果を図 8 に示す。また、ROC 曲線を図 9, 10 に示す。結果より、全体の検出精度は 91.1%と高い精度のモデル作成ができた。カテゴリ別では、正しいセグメントの感度は 90.6%、誤ったセグメントの感度は 91.7%となった。また、適合率は 93.6%、再現率は 90.6%、F 値は 92.1%となった。これらの結果から高精度に動作プリミティブ毎にセグメンテーション可能であることが示唆された。




図 8 混同行列
Figure 8 Confusion matrix.

前後のセグメント区間との相対的な値の特徴量を用いることは動作プリミティブ毎のセグメンテーションの精度を向上させる可能性があることが示唆された。




図 9 ROC 曲線
Figure 9 ROC curve.

セグメントが誤って引かれていた部分には、ワンダリングの速度波形と似ている動きが含まれていた。似ている動きとは、調整時間を含むポインティング動作である。調整時間とは、視覚フィードバックループにより、手の速度を調整しながら目標の刺激まで正確に動かそうとする時に現れる時間である[13]。調整時間が入るとベル型の速度波形が時間軸方向に歪んでしまうことが明らかにされている。つまり図 3 のような速度波形になるがそれを一つのセグメント区間として定義している。角度統計量の観点からワンダリングと調整時間を含むポインティングは明確に異なる。




図 10 ROC 曲線
Figure 10 ROC curve.

つまり前者の場合は集中度が低くなり、後者では集中度が高くなる。しかし、この二つの動作間においては集中度の特徴量はセグメンテーションの精度に寄与しなかったと考える。集中度は方向ベクトルのばらつきを示しているが平均方向ベクトルの向きは考慮していない。図3は調整時間を含むポインティング時の速度波形である。この速度波形は34.33秒で誤ってセグメント境界が設定され、二つのセグメント区間に分かれている。この時、前後のセグメント区間で平均方向ベクトルの向きは同じ方向を向いているはずである。一方でワンダリング時の速度波形も同様に二つのセグメント区間に分割されるが前後のセグメント区間の平均方向ベクトルの向きは同じ方向を向いているとは限らない。したがって、この点に着目して二つのセグメント区間における平均方向ベクトルの内積を考えると、ワンダリングではマイナスの値に近くなり、調整時間を含むポインティングは1に近い値となると考えられる。

5. まとめ

本論文では、Giovannettiらの研究で行われたVR-IADLタスクより得られた時系列データから動作プリミティブ毎にセグメンテーションする方法を提案した。本提案では、高齢者やMCIの動きの特性を考慮した場合のモデルの作成を行った。混同行列の結果より、高精度にセグメンテーション可能となった。今後の展望として、さらなる精度向上のため特徴量の見直しを行う予定である。

謝辞 本研究は科学研究費基盤(C)18K12118 および National Institute on Aging (NIA) R01AG062503 の助成を受けたものである。

参考文献

- [1] “統計局のホームページ”.
<https://www.stat.go.jp/data/topics/topi1211.html>.
- [2] “認知症施策の総合的な推進について-厚生労働省老健局”.
<https://mf.jiho.jp/document/197744>.2019.
- [3] Petersen, R. C.. Mild Cognitive Impairment. The New England Journal of Medicine. 2011, p. 2227-2234.
- [4] Manly, J. J. et al.. Frequency and course of mild cognitive impairment in a multiethnic community. Ann Neurol. 2008, p. 494-506.
- [5] Wadley, V. G. et al.. Mild Cognitive impairment and everyday function: evidence of reduced speech in performing instrumental activities of daily living. The American Journal of Geriatric Psychiatry. 2008, vol.16, no. 5, p. 416-424.
- [6] Yamaguchi, T. et al.. A Dual-Modal Virtual Reality Kitchen(Re) Learning of Everyday Cooking Activities In Alzheimer's Disease. Presence Teleoperators & Virtual Environments. 2012, vol. 21, no. 1, p. 43-57.
- [7] Seligman, S.C. et al.. A New Approach to Characterization of Subtle Errors in Everyday Action : Implications for Mild Cognitive Impairment. The Clinical Neuropsychologist. 2014, vol. 28, no. 1, p. 97- 115.
- [8] 行事光, Tania Giovannetti, 白鳥敦也, 長澤勇貴, 坂本麻衣子, 原田哲也, 山口武彦. Micro-error の工学的モデル化に関する基礎的研究. 電気学会知覚情報研究会. 2019, p. 25-28.
- [9] 長澤勇貴, 行事光, 白鳥敦也, Tania Giovannetti, 原田哲也, 坂本麻衣子, 山口武彦. マルコフ推移確率に基づく Micro-error の発生に関わる IADL 動作プリミティブの推定に関する基礎的研究. ライフサポート学会フロンティア講演会. 2019, p. 104.
- [10] 白鳥敦也, 行事光, 長澤勇貴, Tania Giovannetti, 原田哲也, 坂本麻衣子, 山口武彦. トピックモデルを用いた IADL 動作プリミティブのクラスタリング. ライフサポート学会フロンティア講演会. 2019, p. 105.
- [11] 岩下泰啓, 山口武彦, 坂本麻衣子, Tania Giovannetti. VR-IADL 環境における動作プリミティブの識別モデルに関する基礎的研究. 電気学会知覚情報研究会. 2020, p. 21-25.
- [12] Giovannetti, T. et al.. The Virtual Kitchen Challenge : preliminary data from a novel virtual reality test of mild difficulties in everyday functioning. A Journal on Normal and Dysfunctional Development. 2019, vol. 26, p. 823-841.
- [13] 高嶋和毅. 人の運動特性に基づいたターゲット予測インターフェースに関する研究. 2008.