

# 学位（博士）論文

論文題目

IMUによる人体運動の分節化とパターン認識

Segmentation and pattern recognition of human body movement  
using Inertial Measurement Unit

東京農工大学大学院

工学府

機械システム工学専攻

平成 24 年度入学

学籍番号 12833702

氏名 青木 崇

指導教員 田川 泰敬 教授

受  
理  
印

# 目次

第1章 緒言 .....	2
1.1 研究背景 .....	2
1.2 人体運動の計測方法.....	4
1.3 分節化とパターン認識.....	6
1.4 本研究の目的 .....	7
第2章 計測装置・計測方法.....	8
2.1 IMU (Inertial Measurement Unit).....	8
2.2 計測方法 .....	10
第3章 IMUによる分析手法.....	12
3.1 Signalによる分節化 .....	12
3.2 k近傍法を用いた分節化.....	13
3.3 隠れマルコフモデルによる分節化・認識 <sup>(23)(24)</sup> .....	14
第4章 実験方法・結果, 考察.....	18
4.1 グラスピング実験方法・実験結果.....	18
4.1.1 グラスピング実験.....	18
4.1.2 手動運分節化位置の実証.....	19
4.1.3 結果と考察.....	19
4.2 k近傍法による分節化結果.....	24
4.2.1 被験者1名での実証.....	24
4.2.2 被験者3名での実証.....	28
4.3 太鼓動作の実験方法・実験結果.....	31
4.3.1 IMUによる実験の認識結果①.....	41
4.3.2 IMUによる実験の認識結果②.....	44
4.4 Wiiによる実験方法・実験結果.....	46
4.4.1 Wiiリモコンによる実験結果.....	46
4.4.2 Wiiリモコンによる実験の認識結果.....	52
第5章 結言 .....	54
5.1 考察 .....	54
5.2 今後の展望 .....	56
本論文に関する業績 .....	57
参考文献 .....	59
付録 <sup>(30)(31)(32)</sup> .....	63
付録A フォワードアルゴリズム (Forward Algorithm) .....	63

付録 B Baum-Welch アルゴリズム .....	63
------------------------------	----

# 第 1 章 緒言

## 1.1 研究背景

人体運動の計測は様々な分野で用いられており，人体運動の計測結果を直接利用する方法として，人体運動の計測はスポーツ分野ではトップアスリートの動作解析<sup>(1)</sup>，医療分野ではリハビリテーションの効果評価を数値化<sup>(2)</sup>するためなどがあげられる．数値化のための具体的な方法としては人体の各部位の質量などの計測は，CT や MRI などの医療機器を用いることで得られるが，コストと被験者への負担が多くなる．ロボティクスの分野で開発された力学同定技術を用いることによって，人体の力学同定を行う研究が行われている<sup>(2)(3)</sup>．これらの研究は主にモーションキャプチャなどが用いられており，得られた情報から力学同定や動作解析が行われている<sup>(4)</sup>．しかし，この手法も高額な設備や専門的な知識が必要となり，簡易な人体の各力学パラメータを得る方法があればリハビリテーションの効果を定量的に判断することも可能となる．

また，その他に人体運動の計測結果を用いて認識を行うことでロボットによる外界情報の取得という利用法も考えられる．現在実用化されているロボットの多くは産業分野などの特殊環境で用いられていたが，近年清掃用や警備用などがオフィスや一般家庭における日常生活へと活用の方が広がり始めている<sup>(5)</sup>．また，介護用や医療用の開発も盛んに行われており，ロボット技術の拡大によって人とロボットの距離が近くなっている．これら家庭や公共施設などで人の生活を支援し，人の自立を支援するようなロボットは総称して生活支援ロボットと呼ばれる<sup>(5)</sup>．生活支援分野でロボットを用いるには，人の意思を認識し対応した動きを選択することで人や環境に働きかける機能が必要となる．

内閣府，政策統括官（共生社会政策担当）平成 27 年度版高齢社会白書<sup>(6)</sup>によれば，2060 年には日本総人口の 39.9% が 65 歳以上の高齢者となり超高齢化社会となると報告されている．このためロボットの開発は急務であり，産業界では工場や原子力発電所内など予め使用環境を入力しておくことが可能である特殊環境下で利用されるロボットは，すでに人の代わりとして実用化がなされている．しかし，生活支援分野で用いられるロボットに必要な人とロボットの相互コミュニケーションを実現するために必要となる人の意思を的確に認識する方法は確立されているとは言えない．

産業分野で用いられているロボットとして溶接ロボットがある．溶接ロボットは工場など限定された範囲で予め教師データを入力しておいた溶接作業を行う．

生活支援分野では，現在清掃用ロボットとして東芝ホームアプライアンス社製の『Smarbo(スマーボ)』，iRobot Corporation 製の『ルンバ』やシャープ社製の『Cocorobo』などが一般家庭向けに販売されている．スマーボには加速度センサ，距離検知センサ，ジャイロセンサ，赤外線センサ，カメラなど 38 のセンサが搭載されており，障害物を回避しつ

つ走行したルートを記憶しながら進むため、同じ場所を何度も掃除するといったことがないように制御されており、階段などの危険のある場所は回避するようにできている。各種センサを用いることで、工場などの事前に整えられた条件ではない各家庭によって条件が異なるような環境であっても障害物にぶつかることなく移動することが可能となっている。しかし、現状ではリモコンによる操作や人を避けて掃除をすることは可能であるが、能動的に人の意思を感知するような機能は搭載されていない。

警備用ロボットでは、ALSOK 社製の『ガードロボ D1』などが実用化されており、事前に設定したルートを走行し、その間に人や火災、漏水などの異常を感知し報告する。人が行うには危険な場所や深夜の業務などを行うことが可能となったが、周囲の状況に応じた判断を必要とするような業務には対応できていない。そのため、複雑な判断が必要となる業務には人が対応している。

介護用ロボットとしては（独）理化学研究所と東海ゴム工業(株)が共同開発した『RIBA（リーバ）』などが発表されている。このロボットは腕部に触覚センサを搭載することで人を優しく抱き上げることが可能となった。



Fig. 1.1.1 Smarbo VC-RB100



Fig. 1.1.2 Roomba 780



Fig. 1.1.3 GuardRobo D1



Fig. 1.1.4 RIBA

この様に生活支援分野で活用するため人の意思を認識し、それに対応した動きを選択することができるロボットの開発が盛んに行われている。ここで、人の五感で最も多く用いている感覚は視覚であるといわれており、視覚の中でも人が人の意思を汲み取る際に最も

多く用いているのは人の動作である。このことから人の動作を認識することができれば人の意思をより正確に認識することができるようになると考えられる。

連続した動きを意味のある動作ごとに分けることで対象者が何をしているか、何を表現しているのかといったことを認識することができるようになる。

## 1.2 人体運動の計測方法

動作の認識方法としてモーションキャプチャがあげられ、その代表的な手法として光学式モーションキャプチャがある。光学式モーションキャプチャは専用のスーツを着た人の各部位にマーカを取付け、赤外線を発し反射光を観測することのできるカメラを複数台設置し、マーカの反射光からマーカ位置情報を取得する。加速度の大きな動きにも対応でき、複数のカメラで観測することからオクルージョンが発生しにくいという利点などから人体の運動観測としてスポーツや映画のCG作成など幅広い分野で用いられている。

Fig.1.2.1 に光学式モーションキャプチャによる投球動作の観測実験を行った際の図を示す。図から分かるようにリアルタイムで観測空間内にあるマーカ位置の出力を行うことができる。

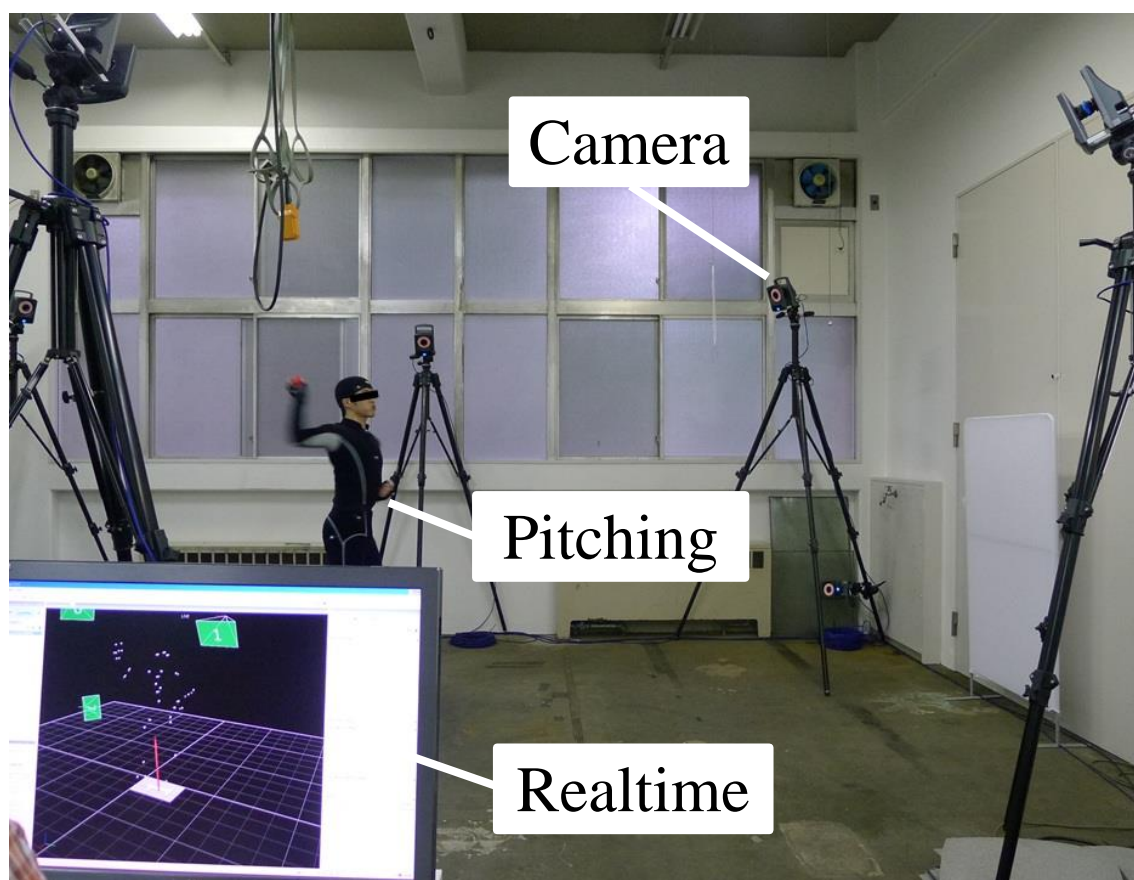


Fig. 1.2.1 Optical Motion Capture

光学式モーショキャプチャ以外に人体の運動を観測する方法として、機械式モーショキャプチャがあげられる。機械式の一つとして加速度・角速度を計測する IMU (Inertial Measurement Unit：慣性計測装置)を体の各部位に取り付ける方法などがある。IMU を用いた全身運動観測方法は Meta Motion 社製の IGS-190<sup>TM</sup> Motion Capture System があり Fig. 1.2.2 にその装着した際の写真を示す。IMU によって全身運動を計測するには専用のスーツによって各関節に IMU を取り付ける必要があり、拘束条件が多くなってしまうという欠点がある。また、逆運動学によって関節角度を求めるため特異点や冗長に対応する必要がある。



Fig.1.2.2 IGS-190<sup>TM</sup> Motion Capture System

IMU センサと同様の機能を持つ機器として、任天堂株式会社からゲーム機用コントローラとして発売されている『Wii リモコンプラス』には三次元加速度センサが内蔵されている。また、床反力計と同様の機能を持つ機器として、Wii リモコン同様に任天堂株式会社より発売されている『バランス Wii ボード』には四方にひずみゲージが配置されており、重心位置などの算出を行うことができる。



Fig. 1.2.3 Wii Remote Plus



Fig. 1.2.4 Balance Wii Board

2012年にマイクロソフト社から発売された『Kinect for Windows』は両端の深度センサにて広範囲に照射された赤外線レーザを取得し、そのパターンの粗さや幾何学的な歪から、範囲内の三次元構造を取得することができる。一般用ゲーム機ということで、他のセンサ類と比較して安価であることと、『Kinect for Windows SDK』などの正式な開発キットが公開されており、開発環境のサポートが充実している。



Fig. 1.2.5 Kinect for Windows

このように人体の動作計測を行うための機器として様々な方法が提案し、開発されている。これらの機器と比較しIMUはゲーム機やスマートフォンに取り入れられるための計器として用いられていることから、量産されており、他の計器と比較すると安価に高精度な製品が市場に出回っている。また、画像データを用いる機器では屋外で使用する場合、逆行やオクルージョンが発生するなどの欠点があるが、これらに対応可能である。

### 1.3 分節化とパターン認識

一連の運動から意味あるまとまりごとに時間軸上で区切ることを分節化と呼ばれている<sup>(7)</sup>。人体の情報取得を行った後、得られた情報を処理することで動きを分析するため、一連の動作を一つの動作単位へと分割する分節化と、分割された動作を事前にラベリングされている動作のどの動きに対応しているかを判定するパターン認識を行うことで、**Human Robot Interaction (HRI)**の分野では、人が事前に想定される動作をロボットが認識し、認識された動作に対応した動きをロボットが選択することなどが可能となる。また、怪我や障害などで回復状況などについても正常な可動が可能となった状態でのモデルと比較することで、リハビリテーションの回復状況を判定する際などを客観的な評価が行われている<sup>(2)(3)</sup>。

稲邑ら<sup>(8)</sup>により見まね学習を通じて原始シンボルを獲得し、高次の知能処理を実現するミメシスモデルが提案されている。運動パターンのダイナミクスの抽象化と原始シンボル化、原始シンボルを用いた他者の運動認識と原始シンボルからの自然な運動パターンの生成を行う学習、認識、生成を一つのシステムで実現でき自律的にデータベースを作成できることが報告されている<sup>(9)(10)</sup>。

高野ら<sup>(11)(12)(13)</sup>によって、光学式モーションキャプチャを用いて取得した人体各部位の位置や各関節角度情報による人体の動作認識を行えるという研究報告がなされている。さらに同様のモデルを用いてモデルの情報が一部消失した場合の認識も行われている<sup>(14)(15)(16)</sup>。



各関節角度情報により取得した運動パターンをモデル化し、新たに観測されたデータがどの運動パターンに分類されるかを判定することにより認識を行っている。

体幹に取り付けられた IMU によって計測された連続した時系列データを一步ごとに分節化を行い一つの歩行周期ごとに分けた後、識別を行う手法が提案されている<sup>(17)</sup>。この手法では、歩行動作は似た波形が連続することから上下の動きを表す Z 軸方向の角速度のみに着目し、一つの歩行サイクル内で起こる周期性を利用し歩行の分節点を決定する手法などがとられた。また、分節化された歩行サイクルから、歩行時の左右の対称性を元に特徴量を決定し、ベイズ識別器を用いて識別を行っている。

画像認識を用いた手法として、ネットワークを介し遠隔でリハビリテーションを支援するシステムが提案されている<sup>(18)</sup>。この研究では、被験者となる患者が上肢を上下させる動作を行い、そのとき上肢をあげられた角度を数値的にとらえ遠隔で情報を取得し、医師がリハビリテーションの状況、患者の診察を行う。

## 1.4 本研究の目的

前述したように、人体運動の観測方法としては光学式モーションキャプチャが多く用いられているが、複数のカメラをトラックとして使用するため、カメラの設置やキャリブレーションに時間がかかる。また、観測範囲内にマーカと同様に赤外線を反射する材質のものがあるとマーカとして認識してしまうため、一般的に観測は光学式モーションキャプチャ専用のスタジオで行われる。三次元空間でマーカの座標を確定するため一つのマーカを複数のカメラで観測する必要があるため観測範囲が限定されることやマーカの装着に時間がかかるなどの煩雑さなどが問題点としてあげられる。日常生活で広く用いることは困難だと考えられる。また、関節角度を算出するには逆運動学の計算が必要となることから、計算量が増えることやそのためのシステムも必要となる。また、位置情報から微分して加速度情報を得ることから、微分誤差を含むという欠点もある。

IMU であればオクルージョンは発生しせず加速度と角速度を直接得られる。しかし、モーションキャプチャとして用いるためには関節角度を得るために逆運動学の計算が必要となり、位置情報を得るには積分が必要となることから積分誤差を含む。

そこで本研究では、人体各部位に IMU を取り付け、取得した加速度・角速度データを直接用いて運動パターンのモデルを作成し、新たに入力された運動とモデルとの比較を行う。この方法により関節角度を用いた方法と比較して安価かつ小規模な設備によって、人体運動のモーション認識を実現する。認識には隠れマルコフモデルを用いる。また、Wii リモコンやスマートフォンを用いても計測を行うことができればより安価に用いることが可能となり、家庭やオフィスなど日常生活での使用に適することができることからこれらの機器を用いた人体運動の認識を行うことを目的とする。

## 第 2 章 計測装置・計測方法

### 2.1 IMU (Inertial Measurement Unit)

IMU は加速度センサと角速度センサが内蔵されているセンサユニットであり、計測可能な軸には製品によって違いがあるが、本稿では加速度センサと角速度センサともに 3 軸計測が可能であるものを用いる。IMU を人体各部位に取り付けることで、光学式モーションキャプチャと同様に全身の運動を取得可能な機械式モーションキャプチャとすることができる。IMU による計測にはオクルージョンが発生しない点や、取り付けられた位置の加速度・角速度を直接取得する点などで、微分誤差を含む光学式モーションキャプチャより優れている点としてあげられる。

しかし、位置情報への変換を行う際は積分処理が必要となり、積分誤差を含むことから優位性を損なう。そこで、本稿では得られた加速度・角速度情報を直接用いることにより、誤差を含みにくいことや計算処理の負担を軽減することができることなどから IMU の出力を直接用いる。

本稿で用いた IMU は『Shimmer2R』と『Pocket IMU』を使用した。『Shimmer2R』と『Pocket IMU』の外観図を Fig. 2.1.1, Fig. 2.1.2 に、仕様をそれぞれ Table 2.1.1, Table 2.1.2 に示す。また、上記は計測用機器として市販されているが、同様に IMU を搭載しているものとして Wii リモコンは任天堂株式会社が 2006 年から発売した家庭用ゲーム機 Wii (ウィー) の専用コントローラである。Wii リモコンには三軸加速度センサが内蔵されており、外部拡張コネクタである Wii モーションプラスにはジャイロセンサが内蔵されており、Wii モーションプラスを取付けることにより加速度・角速度を計測することが可能となっている。2010 年に発売された Wii リモコンプラスにはジャイロセンサが内蔵されたため、Wii リモコンプラス単体で三軸加速度センサとジャイロセンサを同時に取得することが可能となった。Wii リモコン、Wii モーションプラス、Wii リモコンプラスの外観を Fig. 2.1.3 に示す。

リハビリテーションなどの効果評価用として各家庭で用いるためには、より身近で容易に入手できる必要があり、家庭用ゲーム機のコントローラである Wii リモコンが IMU と同様の機能を持っているということから、Wii リモコンによる計測データを用いた認識を試すため、Wii リモコンを計測器として用いることを試みた。

ここで、Wii リモコンは家庭用ゲーム機用のコントローラであり、計測器として市販されていない。そのため公式の仕様は公表されていないため、検証によって得られた仕様を Table 2.1.3 に示す。Bluetooth 通信によりワイヤレスで計測結果を取得する。




Fig.2.1.1 Shimmer2R.

Table 2.1.1 Specification of Shimmer2R<sup>(34)</sup>

Dimension		53×32×16 mm
Mass		25 g
Accelerometer	Range	± 60 g
	Sensitivity	187 mV/g
Gyroscope	Range	± 500 deg/sec
	Sensitivity	2 mV/ (deg/sec)
Data frequency		128 Hz



Fig.2.1.2 Pocket IMU.

Table 2.1.2 Specification of Pocket IMU

Dimension	25(40)×63×101 mm	
Mass	150g	
Data Frequency	60Hz (Maximum)	
Range of Posture Angle	Roll:	±60°
	Pitch:	±60°
	Yaw:	±180°
Range of Angular Velocity	GX,GY:	±300deg/second
	GZ:	±200deg/second
Range of Acceleration	AX,AY:	±1.7G(16.7m/s <sup>2</sup> )
	AZ:	±25G(245m/s <sup>2</sup> )
Sensitivity of Posture Angle	Roll, Pitch, Yaw	0.5deg/rms
Resolution of Angular Velocity	GX,GY:	0.5deg/second
	GZ:	0.3deg/second

Table 2.1.3 Wii Remote specification.

Dimension	30.8×36.2×148 mm	
Mass	113g	
Data Frequency	100Hz (Maximum)	
Operating Time	600 minutes	
Transmission Method	2.4GHz Wireless transmission	
Range of Posture Angle	Roll:	±90°
	Pitch:	±180°
Range of Angular Velocity	GX,GY:	±2000deg/second
	GZ:	±1500deg/second
Range of Acceleration	AX,AY,AZ:	±5G(49.0m/s <sup>2</sup> )




Fig. 2.1.3 Wii Remote.

Wii リモコンと Wii モーションプラスからの角速度出力と Wii リモコンプラスからの角速度出力ではプログラムに変更が必要となる。Wii リモコンプラスには赤枠で囲った位置に「Wii Motion Plus INSIDE」という記載があるので、この部分で判断をする。

Bluetooth にはプラネックスコミュニケーションズ株式会社製の『BT-Micro3E1X』を使用した。Wii リモコンを認識できない Bluetooth があることから本稿で使用した Bluetooth を示す。基本的に下記のようにモトローラ製スタックか東芝製スタックであれば Wii リモコンとの接続が可能である<sup>(19)</sup>。

## 2.2 計測方法

Pocket-IMU はジースポート社から販売されている簡易姿勢計測センサであり、汎用パソコンに専用のソフトウェアをインストールし、付属の Pocket-IMU 受信ユニット (Bluetooth) を取り付けることで計測が可能となることから、計測機器として使用が容易であるという利点がある。Fig. 2.2.1 に専用のソフトウェアのデータ取得中の画面ピクチャを示す。このソフトウェアはデータの受信、保存機能、リアルタイムモニタリング機能、グラフ表示機能と合わせて 3D 骨盤アニメーションの描画機能を有する<sup>(20)</sup>。

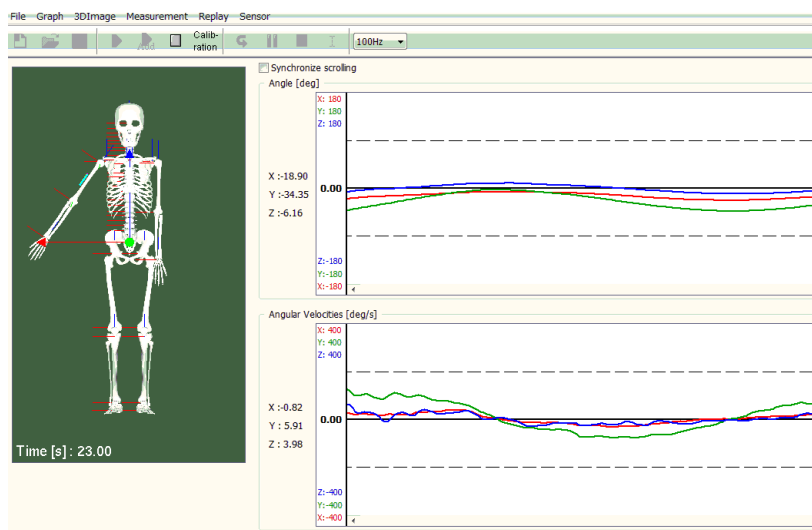


Fig. 2.2.1 Pocket IMU Software

Shimmer は前述の通り IMU は API を MATLAB に読み込み計測を行う。IMU は計測機器として販売されており、比較的容易に行うことが可能である。

ここで、Shimmer2R 複数台からの計測データを同時に取得することができる。各センサの時間同期方法について、複数台同時に計測を行うため、各 Shimmer 内の時計を用いる。各 IMU は計測用パソコンと Bluetooth により通信を行っているが通信の遅延などの影響によ

り、各 IMU 間の計測開始時間に差 $\Delta t$ が発生してしまう。この $\Delta t$ の長さは計測ごとに異なっており、IMU から出力される値は、内部時間とそのときの 3 軸加速度、角速度となっていることから、初めに値を出力した時刻を  $t=0$  とし、続いて出力した IMU の値は、 $\Delta t_1$ 、 $\Delta t_2$ の時間の補正を行うことで複数台の IMU からの出力値の同期を行った。

Wii リモコンによる計測方法について述べる。前述した通り Wii リモコンは家庭用ゲーム機のコントローラであるため、計測は独自に作ったプログラムで行う。このため装置、プログラムの使用上の注意事項について記載する。

Wii リモコンは Bluetooth での接続が可能であることから、Bluetooth による高速通信経路でパソコンへデータを送る。独自に開発されたインターネット上に公開されている API である WiiYourself! Ver1.15a<sup>(21)</sup>を元にデータの取得を行う。プログラムの開発環境には Visual C++ を用いた。API に他に WiimoteLib<sup>(22)</sup>というものが公開されている。WiimoteLib は周期的なデータ取得を行うことができないことからサンプリング周期を一定にすることができないため計測機器としての信頼性に欠けるため、WiiYourself!を用いた。ここで、WiiYourself! Ver.1.15a は Wii リモコンプラスのジャイロセンサ値の取得に対応していない。Wii リモコンと Wii リモコンプラスでは角速度センサのアドレスが変更されていることが分かったため、アドレスの変更を行ったファイル名を WiiYourself!\_1.15\_WiiPlus とした。なお、本研究では計測には Wii リモコンプラスを用いるが、Wii リモコンプラスも Wii リモコンと表記する。

Table 2.2.1 API

API	Programming language	Data acquisition
WiimoteLib	C#/C++	Polling
WiiYourself!	C++	Polling/Continuous

Wii リモコンとの接続のため、Bluetooth を起動し PC と Wii リモコンとのペアリングを行い接続する。ここで接続する Wii リモコンは電池パックを開けたところにある赤い SYNC ボタンを押さないとペアリングを行えないため注意が必要である。また、ペアリングを行った後に接続を行う際は①と②のボタンを同時に押した状態で接続を行う。

Wii リモコンとの接続が完了したら、WiiMyself(青木崇作成)の Measurement プロジェクトを実行する。

現在実装しているサンプリング周波数を約 100 Hz、計測結果を CSV ファイル形式で出力させるプログラム実装までの必要事項を下記に示す。

プログラムを実装するためには Windows Driver Kit をインストールする必要がある。

Wii リモコンの軸設定を下記に示す。各軸の設定は本来任意に設定することが可能であるが API に記述されていた軸設定を基準に設定した。これは将来 Wii リモコンによるデータ計測と分節化、認識プログラムの統合を行うことを考慮し、その際に各軸の識別が容易になるように設定した。出力はリアルタイムで取得可能であることから、その値を直接分節化、認識プログラムへの入力とすることでリアルタイムでの認識が可能となる。

## 第3章 IMUによる分析手法

人が他者の行動を観察したとき、一連の動作を運動パターン毎に区切って動作の認識を行っている。このため、一連の動作を運動パターン毎に分節化することは人体運動のモーション認識を実現するにあたり基本となる重要な情報処理である。運動パターン毎に区切られた計測データに対し、その運動パターンがどの運動パターンと類似しているかを判断することが可能となる。そこで、3種類の分節化手法を検討することとした。3.1節では、体に取り付けた複数台のIMUから得られた情報より最適と思われる特徴量を求め、分節化を行うことを試みた。3.2節でも同様に複数台のIMUからの情報をもとにk近傍法を用いて分節化を行った。3.3節では、人体の各関節角度情報にて行われていたHMMを用いた分節化、パターン認識の手法をIMUから取得した角速度情報へと応用を行った。

### 3.1 Signalによる分節化

複数のIMUセンサから得られた値を一つのスカラー量に変更することで、分節化に適した形へ変更を行うこととした。今回実験で使用した3つのIMUセンサにて説明を行う。また、分節化のために作成したスカラー量をSignalと定義することとする。Signalを利用する利点としては、角速度を直接使用することができることができ、ドリフトといった問題を回避することが可能となる。

左手首、体幹、右手首に取り付けたIMUセンサから得られる3軸の加速度、3軸の角速度を式3.1.1、式3.1.2に示すように定義する。

$$\text{Acc} = \text{Acc}X^2 + \text{Acc}Y^2 + \text{Acc}Z^2 \quad (3.1.1)$$

$$\text{Ang} = \text{Ang}X^2 + \text{Ang}Y^2 + \text{Ang}Z^2 \quad (3.1.2)$$

ここで、AccX, AccY, AccZは加速度のX軸成分, Y軸成分, Z軸成分を表しており, AngX, AngY, AngZは角速度のX軸成分, Y軸成分, Z軸成分を表している。IMUセンサごとにこれらの値を算出し、得られた3つの値の合計値を式3.1.3、式3.1.4に定義する。

$$\text{AccSum} = \text{Acc}1 + \text{Acc}2 + \text{Acc}3 \quad (3.1.3)$$

$$\text{AngSum} = \text{Ang}1 + \text{Ang}2 + \text{Ang}3 \quad (3.1.4)$$

式3.1.3と式3.1.4は単に異なるため、これらの値を各センサの計測範囲を用いて正規化を行う。これを式3.1.5、式3.1.6に示す。

$$\text{AccSum}_{\text{norm}} = \frac{\text{AccSum}}{(\text{Detection range})^2 \cdot 9} \quad (3.1.5)$$

$$\text{AngSum}_{\text{norm}} = \frac{\text{AngSum}}{(\text{Detection range})^2 \cdot 9} \quad (3.1.6)$$

分節化用のシグナルを得るため、重み係数 $e$ を用いることとした。重み係数 $e$ は式3.1.7に示すように定義した。これにより、加速度、角速度双方を利用することが可能となる。

$$e = \frac{\max(\text{AngSum}_{\text{norm}})}{\{\max(\text{AccSum}_{\text{norm}}) + \max(\text{AngSum}_{\text{norm}})\}} \quad (3.1.7)$$

次に，得られた重み係数 $e$ を用いて分節化用スカラー量 $\text{Signal}$ を式3.1.8の様に定義する．

$$\text{Signal} = -(1 - e) \cdot \text{AccSum}_{\text{norm}} + e \cdot \text{AngSum}_{\text{norm}} \quad (3.1.8)$$

得られた $\text{Signal}$ の極小値を用いて分節点を判定する．ここで，加速度の値がマイナスとなっている．これは加速度が大きくなる位置では動きの方向が大きく変更されている点であることから，極小値で判定するため，加速度の値は負へと変換しておくことで加速度最大となる点で極小値を取るように設定した．

作成した $\text{Signal}$ より，Fig. 3.1.1のように極小値，極大値を算出する．算出した値からスライディングウィンドウを設定する．スライディングウィンドウ内の標準偏差が $\text{Signal}$ の最大値の10分の1，かつ直前の極小値からスライディングウィンドウ幅の倍だけ離れており，また，直前の極小値からスライディングウィンドウ内の極小値までの間に極大値がある場合その点を分節点と判定する．




Fig. 3.1.1 Minimum points image

### 3.2 k 近傍法を用いた分節化

$\text{Signal}$ を用いた分節化法ではなく，角速度のみを用いて分節化を行った．各IMUセンサから取得した角速度の絶対値を算出し，式3.2.1を得る．

$$\|\omega_{\text{Position}}\| = \sqrt{\omega_x^2 + \omega_y^2 + \omega_z^2} \quad (3.2.1)$$

ここで，得られた値を式 3.2.2 とし，時系列で並べる．得られた行列を用いて  $k=2$  として  $k$  近傍法にて分類を行った．

$$\omega_{t=t_0} = \begin{bmatrix} \|\omega_{\text{Left}}\|_{t_0} \\ \|\omega_{\text{Body}}\|_{t_0} \\ \|\omega_{\text{Right}}\|_{t_0} \end{bmatrix}^T \quad (3.2.2)$$

得られた値から各フレームの前後数フレーム，ウィンドウサイズを用いる．設定したウィンドウサイズを一つの集まりとし，分節点と判定される部分とそれ以外という2つのクラスに分け，手動にて決められた分節点をもとに各フレームに『分節点』か『分節点でない』というラベルを設定する．Leave-one-outを用いてトレーニングを行い，テストデータとこれと比較することで分節点と分節点でないという判定を行う．Fig. 3.2.1に示す水色の帯びの部分が分節点となる．これによってSignal使用する3.1節の手法と比べて情報損失が少なく済むため，精度の向上が期待される．




Fig. 3.2.1 Example of results of segmentation left hand experiment (*Left hand, center cup*).

### 3.3 隠れマルコフモデルによる分節化・認識 <sup>(23)(24)</sup>

隠れマルコフモデルを用いた音声認識の手法が<sup>(25)</sup>提案されている．この手法に IMU センサから取得した値を用いて認識を行う．

このアルゴリズムでは  $y_1, y_2, y_3, \dots$  を高い次元のデータ系列とし，式 3.3.1 とする

$$x_t = (y_t, y_{t-1}, \dots, y_{t-(m-1)})^\tau \quad (3.3.1)$$

ここで， $m$  は埋め込む次元数， $\tau$  は遅延パラメータとする．埋め込まれたデータの密度分布から長さ  $L$  のスライディングウィンドウ間の密度関数を推定する．ウィンドウ  $\{x_{t-i}\}_{i=0}^{L-1}$  の



データポイントを中心として多変量ガウスカーネル密度推定器を用いて式 3.3.2 を得る.

$$p_{\mathbf{x}}(\mathbf{x}) = \frac{1}{L} \sum_{i=0}^{L-1} \frac{1}{(2\pi\sigma^2)^{d/2}} \exp\left(-\frac{(\mathbf{x} - \mathbf{x}_{t-i})^2}{2\sigma^2}\right) \quad (3.3.2)$$

ここで、カーネル幅  $\sigma$  は平滑パラメータとする. 最適な分布を得るため  $\sigma$  の値が重要であり, 各  $\mathbf{x}_t$  とその初めの  $k$  近傍との平均距離から選択され, サンプルセット  $\{\mathbf{x}_t\}$  によって平均化する. 式 3.3.3 に示すように 2 つの隣接するウィンドウ  $t_1, t_2$  の距離はガウス関数で示すことが可能となる.

$$\begin{aligned} d(p_{t_1}(\mathbf{x}), p_{t_2}(\mathbf{x})) &= \frac{1}{L^2 (4\pi\sigma^2)^{d/2}} \sum_{i,j=0}^{L-1} \left[ \exp\left(-\frac{(x_{t_1-i} - x_{t_1-j})^2}{4\sigma^2}\right) \right. \\ &\quad - 2\exp\left(-\frac{(x_{t_1-i} - x_{t_2-j})^2}{4\sigma^2}\right) \\ &\quad \left. + \exp\left(-\frac{(x_{t_2-i} - x_{t_2-j})^2}{4\sigma^2}\right) \right] \end{aligned} \quad (3.3.3)$$

分節化アルゴリズムは, スライディングウィンドウ  $S$  を用いて隠れマルコフモデルによって実装する. 各ウィンドウは HMM の状態に対応し, 各状態の観測確率分布は式 3.3.4 のように定義される.

$$p(p_t(\mathbf{x}|s)) = \frac{1}{\sqrt{2\pi\zeta}} \exp\left(-\frac{d(p_s(\mathbf{x}), p_t(\mathbf{x}))}{2\zeta^2}\right) \quad (3.3.4)$$

ここで,  $p(p_t(\mathbf{x}|s))$  は状態  $s$  にて  $p_t(\mathbf{x})$  の観測確率である. 初期状態の分布は一様であるとし, 状態  $s_i$  から状態  $s_j$  へ遷移する確率である HMM の遷移行列  $\mathbf{A} = (a_{ij})_{i,j \in S}$  と定義する.

状態遷移行列を同じ状態への遷移確率を異なる状態への遷移確率の  $k$  倍大きく設計すると  $a_{ij}$  は式 3.3.5 の様に表すことができる.

$$a_{ij} = \begin{cases} \frac{k}{k + N - 1} & \text{if } i = j \\ \frac{1}{k + N - 1} & \text{if } i \neq j \end{cases} \quad (3.3.5)$$

ここで,  $N$  は HMM の状態数である. 最適な状態シーケンスを得るためオンラインで変更可能な Viterbi アルゴリズム<sup>(25)</sup>をオンラインで有効に機能する分節化として適応する<sup>(25)(26)</sup>. クリチ, 中村らにより全身の各関節角度データをもとに分節化が提案され実装されている<sup>(26)(28)</sup>. 本研究では, IMU から取得した角速度データを使用して分節化を行っ

た.

続けて、分節化された後、各運動タイプごとに HMM を生成する<sup>(14)(28)</sup>. 本研究では各状態が隣の状態へと遷移する Left-to-Right 型を採用した. 運動パターンを原始シンボルとして抽象化するため、原始シンボルの学習と HMM の強化学習を行う. 分節化と同様に、 $N_u$  個の HMM を用意し、初期パラメータをランダムに設定する.  $j$  番目に分節化された運動パターンに対して最大尤度を出力する HMM を求める.

$$\lambda = \{Q, A, B, \Pi\} \quad (3.4.1)$$

- $Q = \{q_1, \dots, q_n\}$  : 状態の集合  
 $A = \{a_{ij}\}$  :  $q_i$  から  $q_j$  への遷移確率  $a_{ij}$  の集合である状態遷移確率行列  
 $B$  : 状態  $q_i$  で記号列を出力する確率分布集合  
 $\Pi = \{\pi_i\}$  : 初期状態確率の集合

HMM の初期パラメータをランダムに設定するため、計測データに対し最大尤度を出力するように HMM のパラメータを変更する必要がある. また、最大尤度を出力する HMM を求め、パラメータを最適化する. HMM パラメータの最適化には Baum-Welch アルゴリズムを用いて最適化を行う.

計測データ  $o(i)$  から  $N$  個の HMM から生成される尤度をそれぞれ計算する. 大きな尤度を算出した順に HMM を  $m$  個選択し、 $o(i)$  に対して大きな尤度を示した HMM の集合を  $S(i)$  とする.

前述の通り left-to-right 型を採用し、初期状態確率は  $[1, 0, 0, \dots]$  とした. 各状態でのガウス分布は式 3.4.2 のように示すことができる.

$$b_i = \frac{1}{\sqrt{(2\pi)^m |\Sigma_i|}} \exp \left\{ -\frac{1}{2} (\hat{o} - \mu_i)^T \Sigma_i^{-1} (\hat{o} - \mu_i) \right\} \quad (3.4.2)$$

ここで、 $\mu_i$  は平均ベクトル、 $\Sigma_i$  は共分散行列、 $m$  は動作情報の次元を表している<sup>(25)</sup> 更に、モデルとなる原子シンボルを  $N_U$  用意し、HMMs  $\Lambda_k (k = 1, 2, \dots, N_U)$  は状態数 6 または 12 とした. 状態数は経験的に交差検証によって経験的に決定した. 分節化された各動作の尤度計算を行うことで事前に作成した動作モデルの最大尤度を示したものをその動作と認識することとした.

$$\Lambda_{k0} = \arg \max_{\Lambda_k} P(O_{segment}(i) | \Lambda_k) \quad (3.4.3)$$

HMM( $\Lambda_{k0}$ ) を最適化するため、訓練データとして  $O_{segment}(j)$  を保存して用いる. 最適化のために保存したパラメータ数が閾値に達すれば、保存した複数のパターンデータを削除する. パターンデータが閾値未満の場合は HMM( $\Lambda_{max}$ ) の学習を終了する. 閾値に達しなかった場合は次のパターンデータ  $O_{segment}(j+1)$  を訓練データとして処理を行う. 分節化された運動パターンを HMM( $\Lambda_k$ ) に分類し、 $O_{segment}(j)$  に対し最大尤度を出力する HMM( $\Lambda_{max}$ ) のパラ

メータを上記の方法で最適化することによって  $HMM(\Lambda_{max})$  は類似した運動パターンを表現した原始シンボル  $HMM$  となる。認識は  $O_{segment}$  を出力する尤度が最大値を出力する原始シンボルを  $O_{segment}$  と同じ運動パターンであると判定する。なお、この様に算出した  $HMM$  に対する尤度の最適化には **Baum-Welch** アルゴリズムを用いて計算し、運動パターンの認識にはフォワードアルゴリズムを用いて行う。

また、隠れマルコフモデルには潜在変数は何らかの意味を持つと解釈されている。そこで、与えられた計測系列に対し隠れ状態の最も確からしい系列を求めることが必要とされる。隠れマルコフモデルのグラフは有向木であるので、この問題は **max-sum** アルゴリズムを用いて厳密に解くことができる。個々の潜在変数に対してもっとも確からしい状態の集合を求めるにはフォワード-バックワードアルゴリズムを実行して潜在変数の周辺確率を求め、それらの中から独立に最大のものを求めればよい。しかし、一般にはこのような状態の集合は最も確からしい状態系列には対応しない。これは連続する 2 つの状態が単独にはそれぞれ独立に最も確からしくとも、遷移行列中のそれらをつなぐ要素にゼロがあった場合、この状態の集合は確率がゼロとなるためである。

実用的には、最も確からしい状態の系列を見つけることが問題であることから、隠れマルコフモデルの理論では **Viterbi** アルゴリズムを用いることにより、効率的に解くことができる。**Viterbi** アルゴリズムは対数確率を用いるためフォワード-バックワードアルゴリズムとは異なりスケール変数を用いる必要がなく、アンダーフローの問題も解消される。

## 第4章 実験方法・結果, 考察

### 4.1 グラスピング実験方法・実験結果

#### 4.1.1 グラスピング実験

複数の IMU センサを取り付け, 上半身のみの動作を扱う実験を行った. 実験では Shimmer2R を用いた. 日常生活で行うことがある机の上に置かれたコップを取る動作を行わせた. 具体的には, 被験者は机の前に座り, Fig. 4.1.1.1 に示す机の各 5 つの位置に置かれたコップをつかみ, 体の前に移動し体の前に置く動作を行った.

Fig. 4.1.1.2 に示すように左手首, 右手首, 体幹へ IMU センサを取り付けた. 実際に両手で取りに行った場合の各状態を示した図を Fig. 4.1.3 に示す. 被験者が両手でカップを取りに行った際の物である. Fig. 4.1.3(a) は初期姿勢であり, この体制から指定されたコップを, 指定された腕 (および両手) で取る. 初期姿勢からコップを取りに動き出したときを初めの分節点と定義した. Fig. 4.1.3(b) は被験者がコップを掴んだ瞬間であり, このときを2番目の分節点とした. ここで, 被験者の体幹も同時に動いていることがわかる.

続けて, Fig. 4.1.3(c) では被験者がコップを引き寄せ, 自分の前に置いたときを表しており, このときを3番目の分節点とした. 最後に手を初期姿勢に戻したときを示しているのが Fig. 4.1.3(d) であり, このときを4番目の分節点とした.




Fig. 4.1.1.1 Cup layout.




Fig. 4.1.1.2 Attached position of 3 IMU sensors.

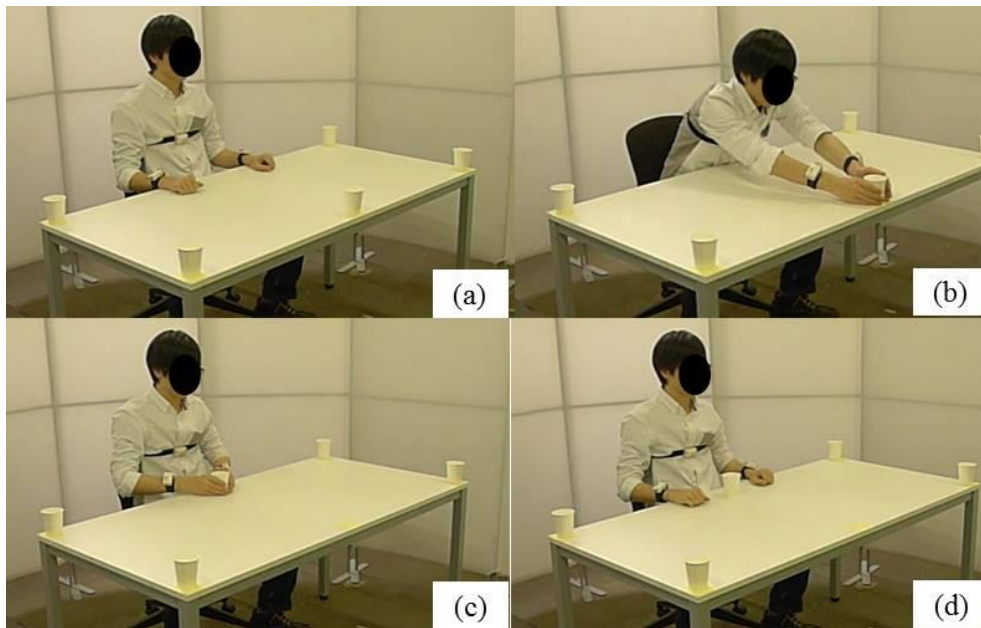


Fig. 4.1.1.3 Condition of grasping experiments (*Both hand, center cup*).

#### 4.1.2 手動運分節化位置の実証

今回の実験では、手動分節点はIMUセンサの波形データと動画データを同期させ、手動にて人が判断した分節点を正しい分節点とした。このとき、水色の帯びで示されている箇所が手動での分節化位置となっている。自動での分節点の判定位置は四角で囲われた個所となっており、判定ができていないことがわかる。ここで、手動で分節点を判定する場合、判別者によって個人誤差が発生する。土支田らの研究<sup>(29)</sup>より5名の被験者により、動画をコマ送りにしそれぞれが分節点だと判断した位置にて手動で分節を行った結果、最大0.82 sの差があり、標準偏差も0.33 sと大きなものとなった。このことから、手動の分節点については複数回行った分節点の平均値から前後±0.2 sを手動での分節結果とした。以下の図で水色示した結果であると、「Manual Seg.」とする。

#### 4.1.3 結果と考察

実験結果をFig. 4.1.3.1～4.1.3.3に示す。被験者が同じコップを右手のみで取った場合の出力結果を示す。Fig. 4.1.3.1からわかるように、右手のみを使ってつかんだため左手首に取り付けたセンサの値はFig. 4.1.3.2とFig. 4.1.3.3と比べて小さな値となっている。




Fig. 4.1.3.1 Results of left hand experiment (*Right hand, center cup*).

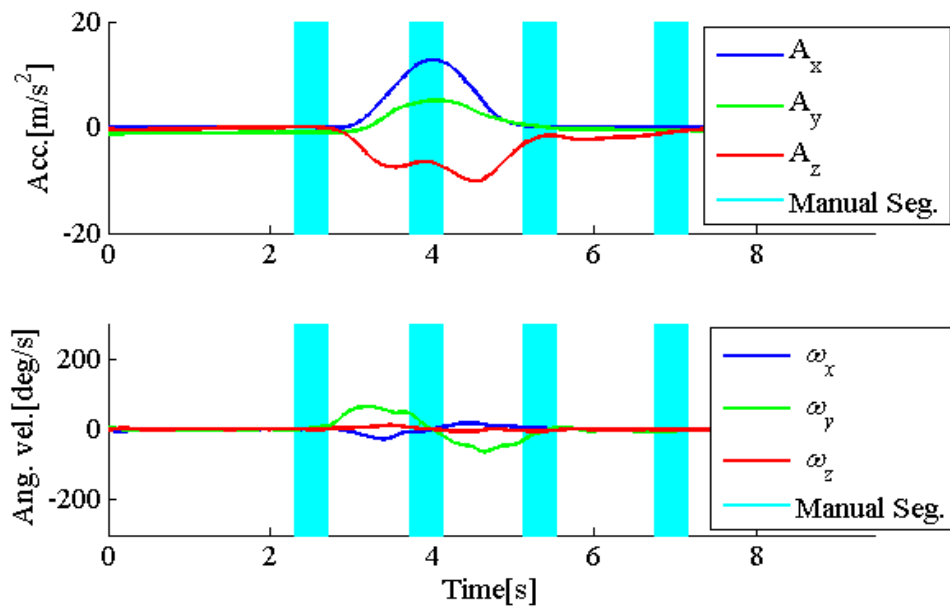


Fig. 4.1.3.2 Results of both hands experiment (*Both hands, center cup*).




Fig. 4.1.3.3 Results of right hand experiment (*Right hand, center cup*).

分節化の結果をFig. 4.1.3.4～4.1.3.6に示す。判定範囲は $\pm 0.2$  sとし、自動判定された分節点が $\pm 0.2$  s以内に納まっている場合、正しい分節位置 (**Correct**) であると判定することとした。その判定結果をTable 4.1.3.1に示す。ここで、手動分節点が不要な位置に自動的分節点が判定された場合を**False positive**と定義し、Fig. 4.1.3.5の3番目の分節点のように、手動的分節点が必要にもかかわらず、自動的分節点が判定されなかった場合を**False negative**と定義した。

Fig. 4.1.3.5は両手でCenter cupを取ったときの実験結果である。3番目の分節点では手動分節範囲外となっているが、隣接した分節がされていることがわかる。Fig. 4.1.3.6は左手でCenter cupと取ったときの実験結果である。最終的分節点が**False negative**となっているが、次の動作にて分節点が表れている。

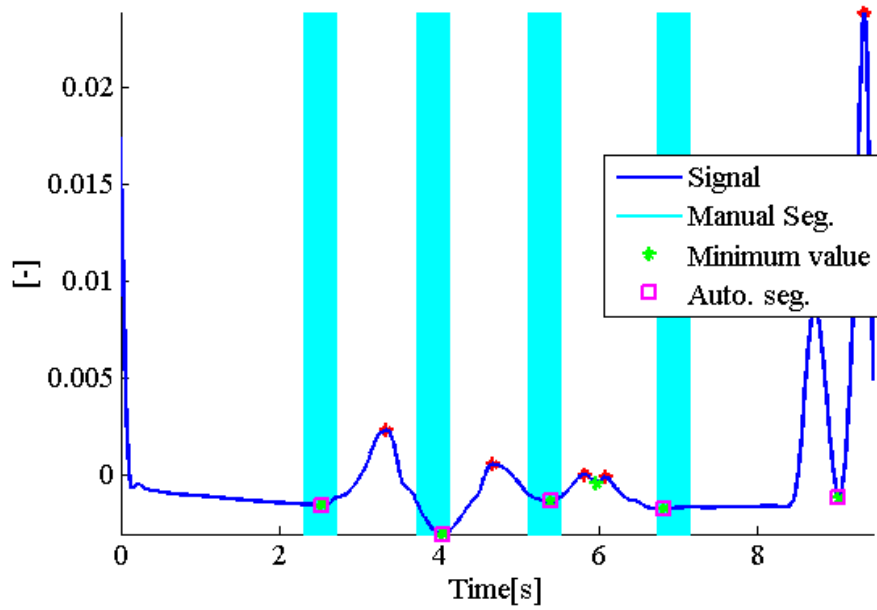


Fig. 4.1.3.4 Results of segmentation right hand experiment (*Right hand, center cup*).

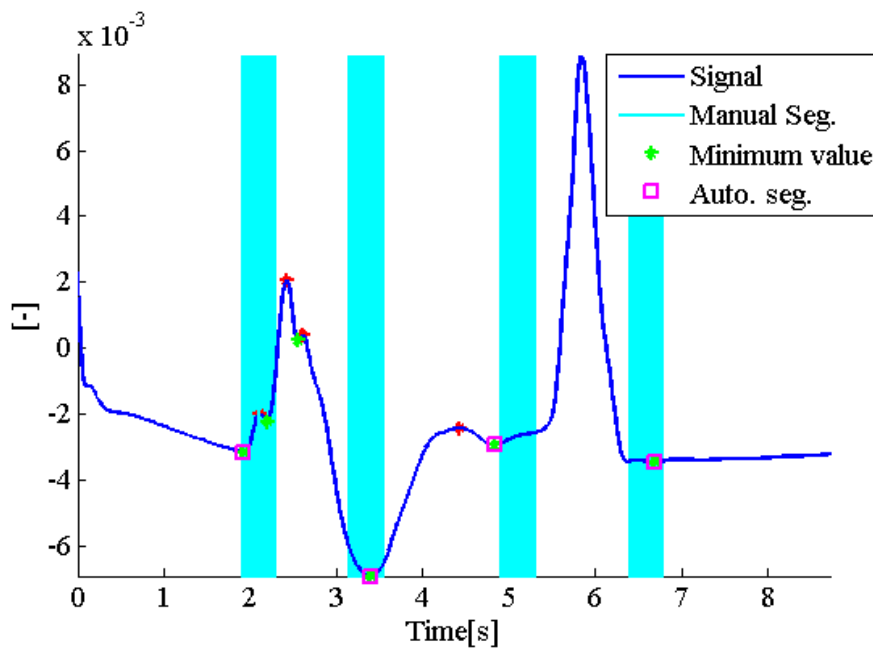


Fig. 4.1.3.5 Results of segmentation both hands experiment (*Both hands, center cup*).



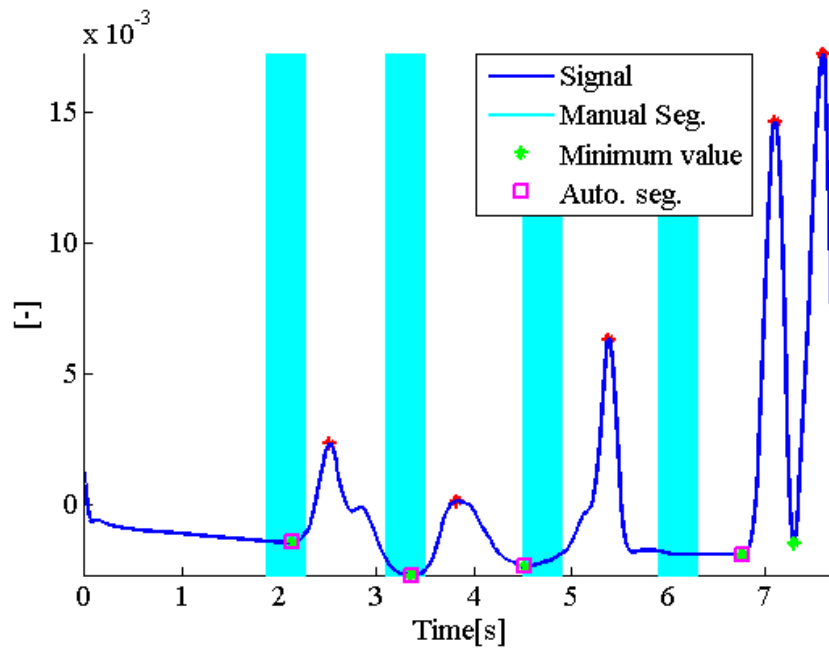


Fig. 4.1.3.6 Results of segmentation left hand experiment (*Left hand, center cup*).

Table 4.1.3.1 Results of auto segmentation

Cup position	Correct ratio	Number of false positive	Number of false negative	Number of segment
Left Side	69%	8	3	36
Left Back	57%	14	1	28
Center	72%	9	0	32
Right Back	47%	20	0	36
Right Side	72%	9	1	36

## 4.2 k 近傍法による分節化結果

### 4.2.1 被験者 1 名での実証

ウィンドウサイズの検討を行った。ウィンドウサイズを対象フレームの前後で使用する。ウィンドウサイズの設定により、精度が異なることから、サイズを変更した場合の分節化結果をTable 4.2.1に示す。水色のバーで示す(a)~(d)はそれぞれの分節位置を示している。この結果より、ウィンドウサイズは19（対象フレームの前後9フレーム）とするのが最も良い結果を得た。

ここで、分節点として判定された場合をSegment, 分節点でない点をNon-segmentと定義した。手動での分節結果が分節点（Segment）であるにも関わらず、分節点でないと判定されていた場合はFalseと判定する。Table 4.2.1の値は、手動での分節点と自動での分節結果が同一である場合の結果を示している。ここで、Fig. 4.2.2によって図の説明を行う。y軸の1および2にある赤色のプロットは真値であり、y=1のとき「Segmentation」、y=2のとき

「Non-segmentation」であることを示している。y軸の-1および-2の位置にある青色のプロットは提案手法によってクラスタリングされた結果を示しており、y=-2のとき「Segmentation」、y=-1のとき「Non-segmentation」であることを示している。このことから、同じフレームにて赤色のプロットと青色のプロットが同じ状態を指名している場合、分節化が正しく行われていることを示している。




Fig. 4.2.1.1 Results of segmentation image.

Table 4.2.1.1 Classification average as a function of window size (Both hands experiments)

	Window size [frame]							
	1	5	7	11	15	17	19	21
<b>Non-seg.</b>	89.0%	89.0%	89.5%	89.5%	89.5%	89.6%	<b>90.0%</b>	89.9%
<b>Segmentation</b>	83.9%	86.4%	87.3%	88.0%	88.6%	88.6%	<b>88.7%</b>	88.7%




Fig. 4.2.1.2 Both hands, grasping the right side cup (*Window size: 1*).




Fig. 4.2.1.3 Both hands, grasping the right side cup (*Window size: 19*).

続けて、各コップの位置に対しての分節化結果を Table 4.2.2 に示す。位置による分節化のぶれも少ないことがわかる。しかし、Fig. 4.2.4 にて水色の円で囲った個所のように分節点と判定されている部分が一部飛んでしまっている点がある。

これを解消するため、分節点が 4 つ連続した場合のみ分節点と判定する様に設定した。この結果を Fig. 4.2.1.5 に示す。

Table 4.2.1.2 Classification results (Average rate of correct classification)

		Left back [%]	Left side [%]	Center [%]	Right side [%]	Right back [%]
Left	Non-seg.	92.0	92.9	92.3	94.1	92.4
	Seg.	90.9	85.8	87.3	86.3	90.4
Both	Non-seg.	85.7	92.0	88.1	90.7	87.0
	Seg.	88.7	88.1	94.8	87.9	90.2
Right	Non-seg.	91.0	94.1	96.5	95.7	93.4
	Seg.	88.3	90.7	87.2	80.2	86.7
Total	Non-seg.	90.6	91.7	94.5	92.5	92.0
	Seg.	88.3	89.5	87.5	85.8	88.2

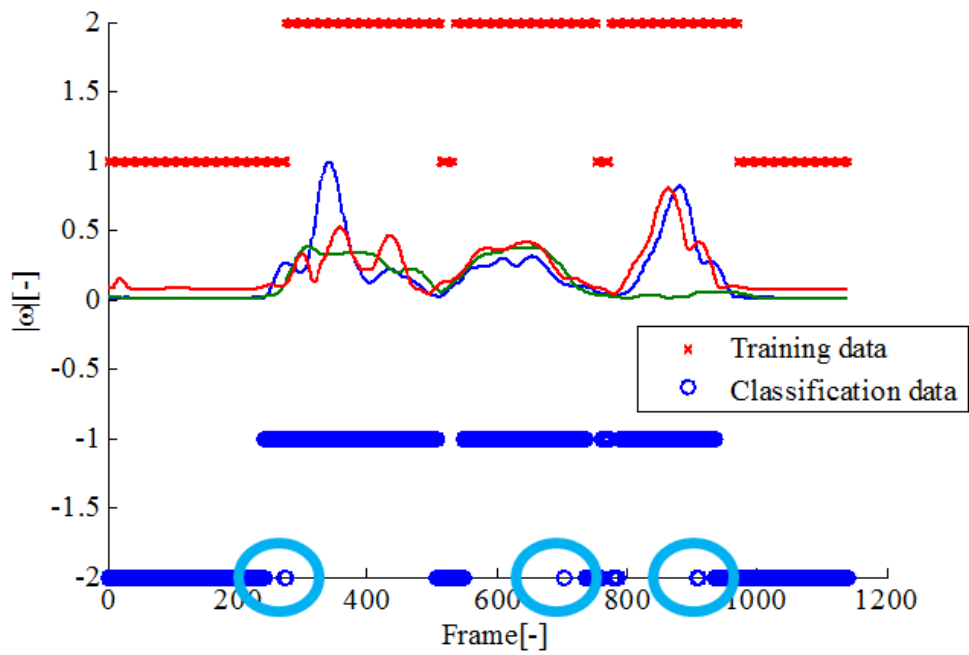


Fig. 4.2.1.4 Both hands, grasping the right side cup (*Not adapted*).

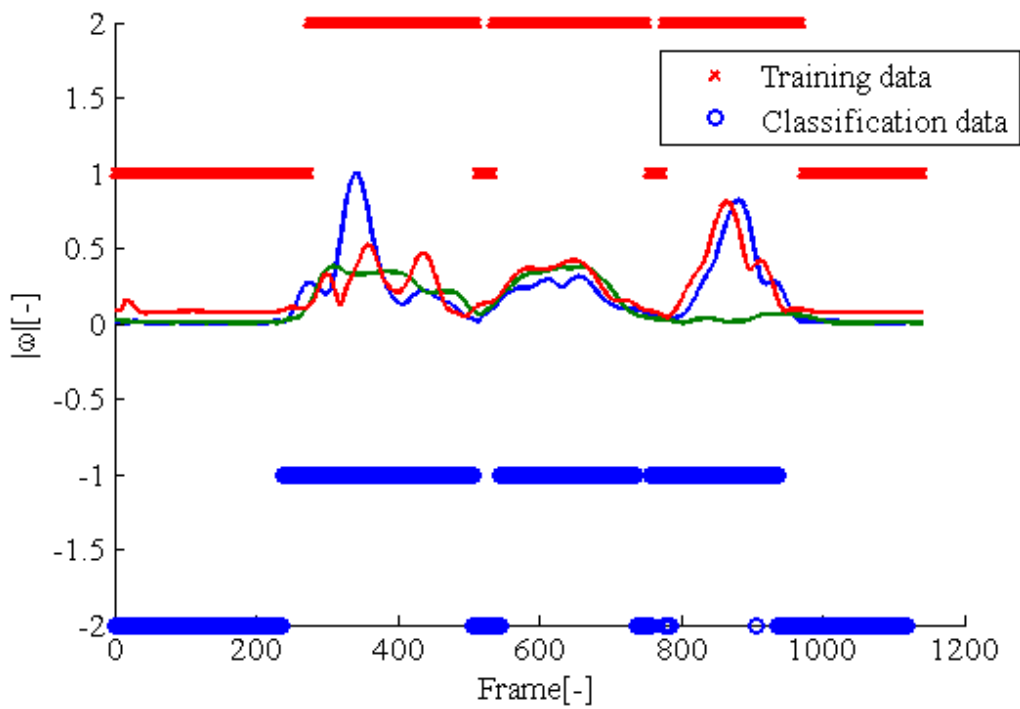


Fig. 4.2.1.5 Both hands, grasping the right side cup (*Adapted*).

#### 4.2.2 被験者3名での実証

被験者3名とし検証を行った。実験は4.1.1項で行った実験と同条件で行った。被験者はいずれも20代の女性2名、男性1名である。実験は各被験者がテーブルの5か所に置かれたコップを各位置3回ずつ計15回計測した各被験者の結果をTable 4.2.2.1~3に示す。この結果は、各被験者が自身のデータをテストデータとして使用し、分類した結果を示している。全ての実験で79.9%以上の分類精度が達成されている。運類率が90%から80%以下に低下する被験者3を除いてこれは許容可能な値であるといえる。

Table 4.2.2.1 Classification results depending on cup position (The average rate of correct, Window size = 19, K = 9, Subject 1, Testing data subject 1)

	Left back [%]	Left side [%]	Center [%]	Right side [%]	Right back [%]
Segmentation	93.2	92.6	92.2	94.0	89.4
	±1.67	±3.52	±2.24	±2.05	±4.35
Non-Segmentation	90.3	79.0	83.6	79.1	90.3
	±4.01	±8.45	±5.01	±14.21	±2.87
<b>Average</b>	<b>91.8</b>	<b>85.8</b>	<b>87.9</b>	<b>86.6</b>	<b>89.9</b>

Table 4.2.2.2 Classification results depending on cup position (The average rate of correct, Window size = 19, K = 9, Subject 2, Testing data subject 2)

	Left back [%]	Left side [%]	Center [%]	Right side [%]	Right back [%]
Segmentation	92.9	92.8	93.3	92.9	94.2
	±0.79	±5.36	±3.36	±5.59	±5.07
Non-Segmentation	89.9	89.1	85.4	87.2	91.1
	±5.04	±6.11	±6.42	±4.99	±9.20
<b>Average</b>	<b>91.4</b>	<b>90.9</b>	<b>89.3</b>	<b>90.1</b>	<b>92.6</b>

Table 4.2.2.3 Classification results depending on cup position (The average rate of correct, Windowsize = 19, K = 9, Subject 3, Testing data subject 3)

	Left back [%]	Left side [%]	Center [%]	Right side [%]	Right back [%]
Segmentaion	81.0	88.3	86.2	88.2	81.8
	±4.61	±4.59	±3.93	±3.34	±5.10
Non-Segmenta tion	78.8	72.1	75.4	74.2	80.0
	±3.17	±5.53	±3.20	±5.31	±5.84
<b>Average</b>	<b>79.9</b>	<b>80.2</b>	<b>80.8</b>	<b>81.2</b>	<b>80.9</b>

分類をする際、テストデータとして被検者本人のデータを用いず、その他の被験者のデータを用いた結果を Table 4.2.2.4~4.2.2.6 に示す。例えば、被験者 1 のデータに対し、テストデータとして被検者 2, 3 を用いた結果である。被験者 3 の分類率は 80%以下に低下するが、その他の被験者では 80%以上の分類精度を示している。

Table 4.2.2.4 Classification results depending on cup position (The average rate of correct, Windowsize = 19, K = 9, Subject 1, Testing data subject 2 and 3)

	Left back [%]	Left side [%]	Center [%]	Right side [%]	Right back [%]
Segmentaion	92.4	88.6	89.8	89.5	85.2
	±1.02	±7.77	±3.36	±2.16	±4.66
Non-Segmenta tion	89.7	81.3	87.5	83.5	90.4
	±4.58	±5.53	±4.69	±5.91	±4.41
<b>Average</b>	<b>91.1</b>	<b>85.0</b>	<b>88.6</b>	<b>86.5</b>	<b>87.8</b>

Table 4.2.2.5 Classification results depending on cup position (The average rate of correct, Windowsize = 19, K = 9, Subject 2, Testing data subject 1 and 3)

	Left back [%]	Left side [%]	Center [%]	Right side [%]	Right back [%]
Segmentaion	99.7	99.7	99.0	99.3	99.7
	±0.25	±0.23	±0.64	±0.52	±0.37
Non-Segmenta tion	99.0	98.5	98.2	98.7	99.1
	±0.59	±1.34	±1.68	±0.57	±0.92
<b>Average</b>	<b>99.3</b>	<b>99.1</b>	<b>98.6</b>	<b>99.0</b>	<b>99.4</b>

Table 4.2.2.6 Classification results depending on cup position(The average rate of correct, Windowsize = 19, K = 9, Subject 3, Testing data subject 2 and 3)

	Left back [%]	Left side [%]	Center [%]	Right side [%]	Right back [%]
Segmentaion	88.7	95.7	89.7	91.2	87.7
	±3.83	±2.59	±1.23	±3.62	±4.03
Non-Segmenta tion	68.8	64.6	65.6	71.5	73.1
	±5.76	±4.93	±6.10	±5.37	±5.84
<b>Average</b>	<b>78.7</b>	<b>80.2</b>	<b>77.7</b>	<b>81.3</b>	<b>80.4</b>



### 4.3 太鼓動作の実験方法・実験結果

実験では被験者の右手首に IMU を取付け、和太鼓を叩く動作を行ったときの右腕の加速度・角速度を IMU によって計測した。実験環境を Fig. 4.3.1 に示す。実験では叩き方を変化させ、異なる動作のデータ取得を行った。

実験にはプロのミュージシャンであり、和太鼓奏者の影山伊作氏に協力していただき、実験は理化学研究所にて行った。また、実験では他の目的で光学式モーションキャプチャでの取得も行ったが本研究では用いていない。IMU による計測とビデオカメラによる撮影結果を用いた。




Fig. 4.3.1 Experimentatal environment

認識に用いるモデル作成のため、IMUCase1 では撥を縦に大きく振上げて叩く動作を 10 回繰り返し行った。IMUCase2 では撥を縦に小さく振上げて叩く動作を 10 回繰り返し行った。IMUCase3 では撥を横に振って叩く動作を 10 回繰り返し行った。これらのモデルを用いて認識を行うため IMUCase4 の実験を行った。IMUCase4 は IMUCase1 と同様の動作を 4 回繰り返し行い、続いて IMUCase1 と IMUCase2 の中間程度の振り上げて叩く動作を 4 回繰り返し行い、最後に IMUCase2 と同様の動作で 4 回繰返して叩いた。これらの実験条件を Table 4.3.1 に示す。

Table 4.3.1 Experimental condition

Name	Movement type		Number of times
IMUCase1	Up-down	Strongly	10
IMUCase2	Up-down	Weakly	10
IMUCase3	Left-to-right	-	10
IMUCase4	Up-down	Strongly	4
		Moderately	4
		Weakly	4

IMUCase1 の実験を行った際の動作を Fig. 4.3.2 に、加速度の出力結果を Fig. 4.3.3 に、角速度の出力結果を Fig. 4.3.4 に示す。撥を振上げた際、手は肩の高さよりも高い位置まで振上げていることが Fig. 4.3.2-⑤の図から分かる。大きく振上げてから太鼓を叩いていることから、叩いたときの音は IMUCase2 と比較して大きなものとなった。



Fig. 4.3.2 IMUCase1 stop motion (Up-down strongly)




Fig. 4.3.3 IMUCase1 Acceleration results (Up-down strongly)




Fig. 4.3.4 TaikoCase1 Angular velocity results (Up-down strongly)

加速度の値は、重力の影響を考慮しない値を出力している。このため  $A_y$  の値が静止時にも加速度がゼロとなっていない。

角速度の出力結果と動作との比較を行う。被験者は同様の動作を 10 回繰り返し行ったため、似た波形が周期的に 10 回繰り返し出力されていることがわかる。初めの 1 回目の波形は他の波形とは異なっており、これは被験者が計測開始時にはティーポーズであったため、太鼓を叩くときに姿勢を動かしたことから連続して叩いたときと比べて異なるうごきとなった。腕を振り上げる前に  $V_z$  の値が大きく変化していることから、腕を太鼓の位置に移動する際に行った動作が出ているものと考えられる。

角速度  $V_x$  に着目すると、 $t=10s$  付近で 3 軸すべての角速度が  $20\text{deg/s}$  以下の値を示している時刻は Fig. 4.3.2-①の姿勢である。その後、腕を振り上げる動作を行い  $t=11s$  付近で  $V_x$ ,  $V_y$  がともに正負が逆転しており、この時刻では Fig. 4.3.2-⑤の姿勢である。腕を振り上げ最高点に達した後、速度は太鼓へ向かう方向に転じる。その後腕を振り下ろして太鼓を叩いた瞬間は  $t=11.13$  に  $V_x$  が 1 周期内で最小値を示し、叩いた直後に腕は静止状態になることから、 $t=12$  付近では再び 3 軸すべての角速度が  $20 \text{ deg/s}$  以下となる。叩いた直後に  $V_z$  の値が大きく振動するのは  $V_z$  が腕の軸方向の回転を取得しているため叩いた直後に腕がはじかれたために軸方向に不規則に回転していることがわかる。

IMUCase2 の実験を行った際の動作を Fig. 4.3.5 に、加速度の出力結果を Fig. 4.3.6、角速度の出力結果を Fig. 4.3.7 に示す。撥を振り上げはほとんど行わずに、叩いていることが Fig. 4.3.5-②の図から分かる。振り上げをほとんど行っていないことから、叩いたときの音は IMUCase1 と比較して非常に小さな音となった。

グラフより IMUCase1 と同様に同じ波形が 10 回繰り返し返されていることがわかる。IMUCase1 と比べて  $V_x$ ,  $V_y$  は振幅が小さくなっており、 $V_z$  の値は同様の波形であることがわかる。IMUCase1  $V_x$ ,  $V_y$  の波形が IMUCase1 と同様の波形となっていることがわかる。



Fig. 4.3.5 TaikoCase2 stop motion (Up-down small)




Fig. 4.3.6 IMUCase2 Acceleration results (Up-down small)




Fig. 4.3.7 IMUCase2 Angular velocity results (Up-down small)

IMUCase3 の実験を行ったときの動作を Fig. 4.3.8 に、加速度の出力結果を Fig. 4.3.9, 角速度の出力結果を Fig. 4.3.10 に示す. 撥を振り上げずに体の左から右へと横に叩いていることが Fig. 4.3.8 の図からわかる.



Fig. 4.3.8 TaikoCase3 stop motion (Left-to-right moderately)

IMUCase1, IMUCase2 と比較して波形が明らかに異なることがわかる. こちらも  $V_x$  に着目すると,  $t=10s$  付近で速度の方向が正となり再び負となるまでが Fig. 4.3.8-①～⑤の区間であり, そこから負の値から正の値へ転じるまでが Fig. 4.3.8-⑤～⑧の区間である.

腕を振り切った流れでそのまま叩き始めるため, 角速度が静止状態を示すことがない. また, 動画で確認すると明らかであるが, 叩き方が他の動きと比べて規則性に欠けるため, 周期性は変わらないが波形に違いがある. 具体的には1周期ごとに  $V_x$  のピークが少しずつ大きくなり, 逆に  $V_y$  のピークは小さくなっており, 動画でも叩くときの腕の角度が変化していることを確認できた.




Fig. 4.3.9 IMUCase3 Acceleration results (Left-to-right)




Fig. 4.3.10 IMUCase3 Angular velocity results (Left-to-right)

次に IMUCase4 の実験結果を示す。太鼓を上から大きく振上げて叩く、中程度に振上げて叩く、小さく振上げて叩く動作を各 4 回ずつ計測した動作である。加速度の出力結果を Fig. 4.3.11, 角速度の出力結果を Fig. 4.3.12 に示す。

波形から初めの 4 周期は IMUCase1 と同様の波形であることがわかる。また、中間の 4 回は IMUCase1 の波形が小さくなり IMUCase2 の波形との中間であることがわかる。最後の 4 回は IMUCase2 と同様の波形であり、それぞれ波形が取れていることが確認できた。ここで、この動作を行ったとき右手だけで連続して叩くのではなく、右手で叩き、左手で叩き、右手で叩くという方法で計測したため、一つの波形から次の波形移るまでの時間が長いことがわかる。また、最後の 4 回はそれまでの波形と比べて非常に小さいため縦軸を同じにしていると波形を読むことができないほど小さな波形となっている。




Fig. 4.3.11 IMUCase4 Acceleration results






Fig. 4.3.12 IMUCase4 Angular velocity results

続いて取得したデータの分節化を行った後に認識を行う。そこで基本となる運動パターンの分節位置についての説明を行う。分節位置とは運動の切れ目のことであり、分節化を行わなければ異なる運動を認識することができないため重要な要素である。3章で説明した自動分節化のアルゴリズムを用い、取得した波形から一つの運動パターンであるといえる区間ごとに運動を区切った。加速度、角速度のすべてを用いると分節のパラメータ設定に時間を有し、認識を実行し有用性を確認するため、本稿では分節化には角速度  $V_x$ ,  $V_y$  の出力結果のみを用い分節化を行った。

IMUCase1 の上から大きく振上げて叩く動作の分節位置を例に分節位置についての説明を行う。人が判断する分節化の方法は、同時に撮影した動画と波形を比較して分節位置を決定する。

『腕を振上げてから叩く』まで Fig. 4.3.13-①～⑧までの一連の動作を一つの運動パターンであるとした。人が太鼓を叩く動作を見たとき『腕を上げて、下げて叩く動作』までの動作を『太鼓を叩く動作』という一つの運動パターンだと判断する。人が分節位置だと判断する位置は Fig. 4.3.13 の左図の位置を正しい分節位置であるとした。

Fig. 4.3.14 の右図は Fig. 4.3.13-①～⑤の区間の『腕を振り上げる動作』を一つの運動パターン、Fig. 4.3.13-⑤～⑧の区間の『腕を下して叩く動作』を一つの運動パターンと判断した場合の分節位置となっている。このように太鼓を叩く動作は『腕を上げる動作』と『腕を下げて叩く動作』との2つの運動パターンと考えることも可能である。この運動パターンの

区切り方は、人が動作の切り替えを行うときは、一度角速度がゼロとなり停止するという考え方を元に考えることができる。実際にこの条件が当てはまる場合もあるが、この分節位置を採用した場合、角速度がゼロとなる位置を分節点とすることから HMM を用いた特徴量の変化による分節化を用いているのではなく、各軸の角速度がゼロ近傍となった位置を分節点とすればよいこととなるが、HMM による分節化の利点を有効にするため『腕を上げて、下げて叩く動作』を運動パターンとした。



Fig. 4.3.13 Segmentation position




Fig. 4.3.14 Segmentation position difference

### 4.3.1 IMUによる実験の認識結果①

IMUCase1 を分節化した結果を Fig. 4.3.1.1 に示す.




Fig. 4.3.1.1 IMUCase1 Segmentation Results

グラフから分かるように、手動での分節位置と等しい結果が得られたが、1回目の動作は分節位置がずれていることが分かる。これは動作のスタート時であったため、波形も他の動作と異なっていることから分節が切れなかったものと考えられる。

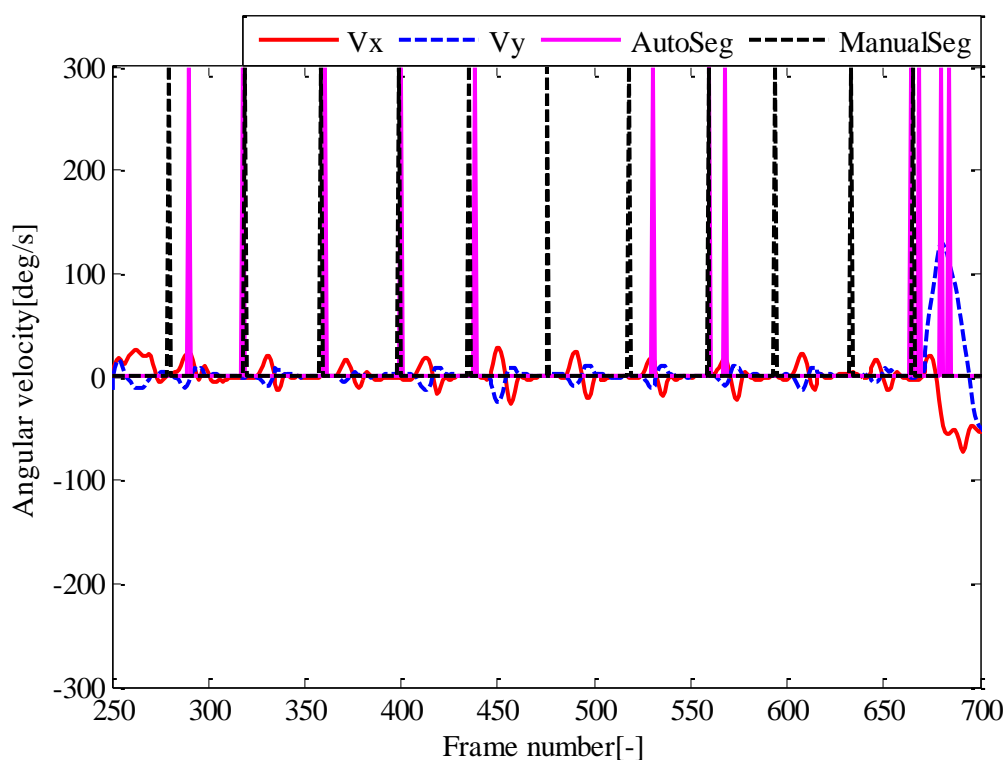


Fig. 4.3.1.2 IMUCase2 Segmentation Results

IMUCase2 の弱く叩いた動きでは分節化が完全には行われていない，IMUCase1 と比較して最大値も  $50\text{m/s}^2$  以下であり，一つの運動パターンとして分節化されなかった．分節化できている点も数点あるが，分節化には検討が必要である．この分節化の問題は加速度の値を分節化に用いることで解決するものと考えている．分節化には課題が残っているが，検証を進めるため，認識を行うこととした．

続いて，モデルを作成し IMUCase1 の認識を行った結果を示す．設定した使用したモデルを Table 4.3.1.1 に示し，認識結果を Table 4.3.1.2 に示す．検証のため，動作がモデルに含まれている IMUCase1 を認識する対象とした．

ここで，運動パターン③を除くすべての結果で IMUModel 1 が最大尤度を出力しており，認識が行えていることから認識は行えていることが確認できたと考え，次に認識用に取得した IMU Case4 の認識を行った．

Table 4.3.1.1 IMU Model setting

IMUModel 1	IMUCase1
IMUModel 2	IMUCase2
IMUModel 3	IMUCase3

説明のため運動パターンに①から⑨の番号を付け、Table 4.3.1.2 の値は各運動パターンに対する各モデルの対数尤度であり、絶対値が小さいほど、その運動パターンを出力する確率が高いという結果であることを示している。認識に用いた HMM は状態数 6 とした。運動パターン③で尤度が IMUModel 2 が絶対値最小の値を示している。この運動パターンに対する全ての尤度が他のパターンに対する尤度と比べて大きな値となっている。このことから波形をうまく認識できていないことがわかる。

Table 4.3.1.2 IMU Case1 recognition results

	①	②	③	④	⑤	⑥	⑦	⑧	⑨
IMUModel 1	-88.1	-63.1	-25.6	-97.5	-58.3	-104.6	-65.6	-39.7	-46.4
IMUModel 2	-1012.9	-176.2	-18.7	-1555.8	-266.3	-1417.6	-377.9	-320.9	-60.5
IMUModel 3	-145.6	-89.9	-34.4	-174.0	-87.8	-167.6	-119.1	-116.7	-149.9

\*Log likelihood




Fig. 4.3.1.3 IMUCase1 Segmentation and Motion pattern number

### 4.3.2 IMU による実験の認識結果②

続いて IMUCase4 の認識を行った結果を示す。取得した波形の分節化を行い、その各運動パターンに対して認識を行うため、先に自動分割化の結果について記述する。初めの 8 回までは波形が大きいためうまく分節化ができています。しかし、10 回目と 11 回目の叩き方の間に分節点が出ていない。これは 1 回目から 8 回目の動作と比べて 9 回目から 12 回目の波形が非常に小さいことと、さらに 9 回目から 12 回目の波形の中でも特に 11 回目の波形が小さいため、一つの運動パターンと認識されなかったものと考えている。この件に関しては検討が必要である。また、運動パターン⑫は叩き終わった後に被験者が太鼓を叩かなかったが叩く動作を行ったときの波形である。

認識結果は運動パターン①から⑥では IMUModel 1 となり、運動パターン⑦から⑨は IMUModel 2 と認識され、運動パターン⑩も同様に認識された。

しかし、運動パターン⑦、⑧は人が判断した場合 IMUModel 1 と判断するのが妥当であると考えられることから、波形の大小の認識には改良の余地がある。しかし、IMU Model 3 であると認識は一つもなく、基本的な動作の違いは認識できているといえる。

Table 4.3.2.1 IMUCase4 recognition results

	①	②	③	④	⑤	⑥	⑦
IMU Model 1	-18.6	-14.1	-16.9	-19.1	-28.1	-24.3	-70.2
IMU Model 2	-20.9	-20.9	-48.7	-21.6	-34.3	-32.9	-61.8
IMU Model 3	-29.9	-30.0	-75.9	-29.5	-52.1	-52.4	-97.4
	⑧	⑨	⑩	⑪	⑫		
IMU Model 1	-45.7	-25.9	-57.2	-77.8	-85.6		
IMU Model 2	-19.0	-14.2	-47.6	-47.9	-125.6		
IMU Model 3	-51.1	-29.0	-74.0	-94.7	-122.0		

\*Log likelihood




Fig. 4.3.2.1 IMUCase4 Segmentation

## 4.4 Wiiによる実験方法・実験結果

### 4.4.1 Wii リモコンによる実験結果

Wii リモコンを右腕に持ち腕を縦に強く振った。Wii リモコンの持ち方を Fig. 4.4.1.1 に示すようになった。実験では被験者は右手で Wii リモコンを持ち、Wii リモコンを振って加速度・角速度を計測した。実験時の Wii リモコンの持ち方を Fig. 4.4.1.1 に示す。Wii リモコンは IMU とは異なり取付けを行うわけではないが、持ち方は決めないと同じ動作であっても認識ができないため同じ持ち方をする必要がある。

振り方を変化させ、異なる動作によって得られた出力を用いて分節化、認識を行う。WiiCase1 では Wii リモコンを縦に大きく振る動作を 10 回繰り返し行った。WiiCase2 では Wii リモコンを縦に小さく振る動作を 10 回繰り返し行った。WiiCase3 では Wii リモコンを横に振る動作を 10 回繰り返し行った。Table 4.4.1.1 に各実験条件を示す。

Table 4.4.1.1 Experimental condition

Name	Movement type		Number of times
WiiCase1	Up-down	Widely	10
WiiCase2	Up-down	Small	10
WiiCase3	Left-to-right	-	10
IMUCase4	Up-down	Widely	4
		Moderately	4
		Small	4



Fig. 4.4.1.1 Wii Remote holding

WiiCase1 の実験は Wii リモコンを Fig. 4.4.1.2 のように縦に大きく振った。IMU と同様に計測が行えていることが確認できた。値が IMU の実験と比べて大きくなっている理由は、IMU は腕に取り付けていたため加速度、角速度ともに小さくなったことが言える。検証のため、Wii リモコンを腕に取り付けて太鼓を叩くような動作を行ったが、角速度は IMU の実験と同じような範囲の計測結果となった。





Fig. 4.4.1.2 WiiCase1 stop motion




Fig. 4.4.1.3 WiiCase1 Acceleration results




Fig. 4.4.1.4 WiiCase1 Angular velocity results

WiiCase2 の実験は Wii リモコンを Fig. 4.4.1.5 のように小さく振った。この動作は WiiCase1 の動きと似た動作である。

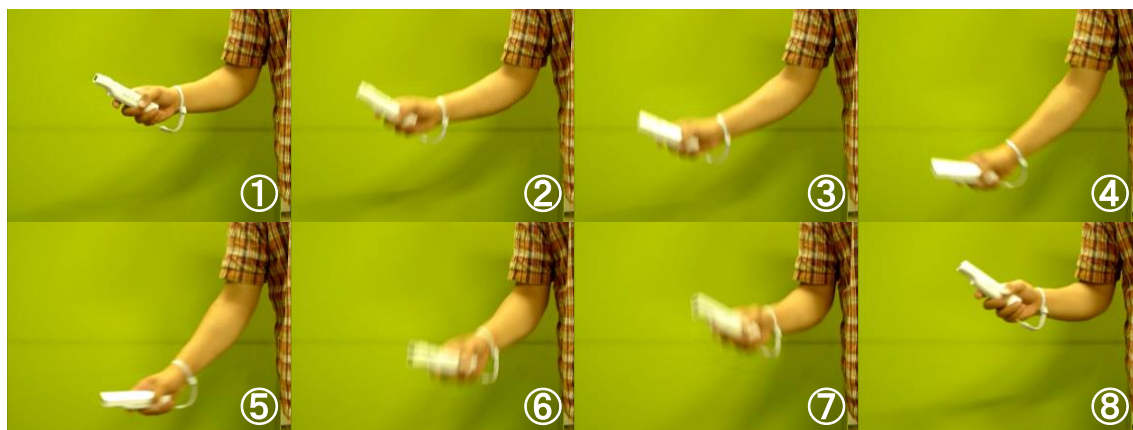


Fig. 4.4.1.5 WiiCase2 stop motion




Fig. 4.4.1.6 WiiCase2 Acceleration results




Fig. 4.4.1.7 WiiCase2 Angular velocity results




Fig. 4.4.1.8 WiiCase3 stop motion




Fig. 4.4.1.9 WiiCase3 Acceleration results




Fig. 4.4.1.10 WiiCase3 Angular velocity results

WiiCase1 は上から大きく振る動作， WiiCase2 は上から小さく振る動作， WiiCase3 は横に振る動作であり， WiiCase1 と WiiCase2 の波形は似ており， WiiCase3 は明らかに異なる動作であることがわかる．

#### 4.4.2 Wii リモコンによる実験の認識結果

前述した通り，Wii リモコンによる分節化は的確に行えているといえるが，10回の動作に対して最後の10回目は続く動作がなかったため分節化されず，運動パターンとして認識できていない．各モデルを Table 4.4.2.1 に，WiiCase1 の認識結果である対数尤度を Table 4.4.2.2 に示し，対応するグラフを Fig. 4.4.2.1 に示す．結果より，運動パターン⑤以外は WiiModel 1 と認識できた．ここで，運動パターン⑤は波形より，振り下げた後の  $V_y$  が大きく正になっており，ほかの波形と異なっているため，認識がうまくできなかったものと考えている．

Table 4.4.2.1 Wii Model setting

Wii Model 1	WiiCase1
Wii Model 2	WiiCase2
Wii Model 3	WiiCase3

Table 4.4.2.2 Wii Remote Recognition results

	①	②	③	④	⑤	⑥	⑦	⑧	⑨
WiiModel 1	-129.3	-27.4	-92.0	-117.8	-109.6	-168.6	-89.0	-153.3	-137.4
WiiModel 2	-149.8	-34.8	-118.9	-147.2	-146.3	-204.5	-118.3	-177.0	-150.5
WiiModel 3	-143.1	-32.1	-112.8	-139.2	-77.6	-194.1	-93.5	-167.6	-143.6

\*Log likelihood




Fig. 4.4.2.1 WiiCase1 Segmentation and Motion pattern number

Wii リモコンによる加速度・角速度の計測を行った。Wii リモコンは IMU と比べて計測範囲が広いという利点がある一方、計測範囲が広いと精度保証がない欠点もある。さらに、家庭用ゲーム機であるため精度保証は困難であるが、分節化や認識は行えることが確認できたことから計測機器として使用して問題ないといえる。

計測のためのプログラム作成を行う必要があり、Wii リモコンの仕様に変更があるとプログラムの変更が必要となる。しかし、今後新たな計測機器が発売された場合でも、今回作成した経験から計測用のプログラムを作成することができると考えられる。

IMU による分節化はパラメータを変更しないと分節位置を人が分節位置と判断する位置で分節することができなかった。Wii リモコンは手に持って計測を行うため角速度の値が大きくなるため変化が顕著であり、分節化がどの設定であっても行えることが確認できた。

しかし、運動の違いを細かく判断するには入力内容が多く認識率が上がることから、入力情報を増やすために加速度情報を加えることが必要となる。

しかし、加速度を加えると自動分節化を行う際に運動パターンとして分類化しにくいため分節化がうまくいかなくなるという課題がある。この課題を解決するため、角速度による分節化と加速度による分節化を個別に行い分節点を出力し、統合することが考えられる。

## 第 5 章 結言

### 5.1 考察

それぞれの手法で使用した計測データについて下記の表にまとめた。

Table 5.1.1 Analysis usage data

	Signal	kNN	HMM
Number of dimensions	18	9	2
Physical information	Acceleration 3×3 Angular velocity 3×3	Angular velocity 3×3	Angular velocity (X axis + Y axis)

3 台の IMU を用いた実験で、3 つのセンサの値を用いた分節化法について検討を行い 2 種類の手法を試した。真値として用いた手動の分節化結果には個人誤差が発生しておりその範囲を判定することを行った。ここで、動作の切替わり時点の判定者により事前に分節位置を通知せずに切り替わり時点を判定させると、位置が異なったり、動作の動き出しから完全に動作が終了した時点を終了時点と判定することがあった。これでは今後区切られた動作を認識する場合に不都合があることから、実験管理者の主観から分節位置はモーションプリミティブ<sup>(10)</sup>で区切るよう事前に指示を出したうえで、改めて分節点の判定を行った。

Signal を用いた手法では、各 IMU の値を一つの Signal というベクトルを作成し、その極小値から分節点となる点をアルゴリズムにより決定した。過去の研究では、角速度のみを使用し、角速度がゼロとなった位置を分節点とするゼロクロッシング手法が使用されていた<sup>(29)</sup>。しかし、この手法では、動作の開始点や動作の切り替わり点は 3 つのセンサ、各 3 軸の角速度はゼロとはならず、分節点として判定することができなかった。そのため、動作が立ち上がった点などを判定するアルゴリズムを取り入れるなどし、判定を行うことを行ったが、高い分節化率を得るには被験者ごとにパラメータを設定する必要があった。

そこで、加速度と角速度を用いることで、単純に角速度がゼロとなり動作が停止したときを分節点と判定するのではなく、加速度最大となる動きの方向が切り替わるときも分節点として判定する手法を取り入れた。その結果初期姿勢からコップを取るために動き出した瞬間も加速度が大きくなることから分節点として判定することが可能であることを示した。Correct ratio は最大で Center と Right Side の位置のとき 72% と良い結果を示したが、Right Back の位置では 47% と良好な結果を得ることはできなかった。ウィンドウサイズが大きい点やパラメータが多いといった点、情報損失が大きい点などで他のシステムに応用するには課題が残されている。

そこで上記の Signal を用いる手法とは異なる特徴量を用いることで、分節点と分節点で



ない点に分け、3つのセンサ、各3軸の角速度をk近傍法を用いて分節化することを試みた。この手法については、加速度のみ、加速度・角速度両方を用いた検証も行ったが50%を上回る様な結果を得ることがでいなかったため角速度のみを用い、さらに検証を行った。これは加速度の波形が安定せず、特にコップを掴んだ時点での分節化ができなかったことが要因であると考えている。分節点と分節点でない点の2つのクラスとして分類することでSignalを用いた手法より分節の精度を向上させることが可能となった。また、この手法であれば、分節でないと判定された点について同様のアルゴリズムを用いて認識も行うことが可能である。このk近傍法を用いた手法では最大で89.5%と高い確率で分節点を得ることが可能となりコップの位置によるばらつきも発生しにくいということが分かった。これによって、複数台のIMUによる人体の動作情報を取得し、そのデータから動作が切り替わる点と切替わらない点を判定することが可能となった。この手法により、被験者が異なる場合についても高い分節化成功率を実現できることが示された。

1台のIMUを用いた実験に加えて、分節化と認識を行った。過去の研究で人体の関節角度を用いて行われていた手法をIMUの値をそのまま使用し、分節化と認識が一連の流れで実装可能であることを示している。

実験は太鼓を叩く動作を判定することを行い、各動作をモデル化することで被験者が太鼓をどのように叩いているかの判定を行うことが可能であることを示した。

太鼓に似た動作として、Wiiリモコンを用いた実験を行い、同様にモデル化することで、モデルと比較することでどの振り方をしているかの判定を行った。モデルを増やすことでどのような動作をしているのかを判定することが可能となった。80%以上の確率で認識ができることが示された。ただし、隠れマルコフモデルを用いた手法では、情報が多くなり過ぎると分節化の過程でパラメータの設定が困難になる。このため、使用した情報も角速度のX軸、Y軸のみとした。また、異なる被験者のモデルを使用したことろ分節化、認識ともにできず、これについてもパラメータの再設定が必要である。HMMを用いて3台のIMUから取得した加速度、角速度それぞれ3軸の情報を取り込んで行った結果、パラメータの設定のみでは真値に近い値を得ることはできなかった。

これらの結果から、Signalを用いた手法は、取得したデータを全て使用でき波形も視覚的に判断できるという利点はあるものの、パラメータ調整に時間がかかり、設定したパラメータで他の被験者では高い分節化成功率を得ることができないという欠点もあることが判明した。隠れマルコフモデルを用いた手法では、分節化、認識を行うことができることは示されたが、異なるSignal法と同様に異なる被験者では満足な結果を得られなかった。また、実装に用いたデータが角速度のX軸、Y軸のみと非常に少なかったため、撥を振るような単純な動作には対応できたが、コップを掴むという複雑な動作に対応できなかった。

その点、k近傍法を用いた手法では、角速度のみとはなったが他者のデータを用いても分節化が実装でき、パラメータの調整にも比較的時間がかからなかった。これらのことから人体の動きを先端に取り付けられたセンサ情報にて分節化を行うためには、k近傍法を用い

た手法が最も優れている物と判断した。

## 5.2 今後の展望

### 1. 分節化プログラムと認識プログラムの分割

現在はリアルタイムでの認識を行うため分節化を行い、その分節化結果を用い、モデルを作成し、認識を行っている。そのため認識結果の評価については、うまくいかない場合、分節化プログラムの影響にもよるものか、認識プログラムの影響によるものか判断が難しかった。

今後は、Wii リモコンから取得したデータをリアルタイムで分節化する分節化プログラムを作成し、認識プログラムは人が分節化した波形を用いて認識結果の検証を行うこととする。

### 2. リアルタイム分節化プログラムの作成

分節化プログラムについては独立して改良することにより、分節化の精度を向上させる。分節化に隠れマルコフモデルではなく、提案されている他の手法<sup>(12)(13)</sup>を用いた分節化を試みる。

### 3. 認識プログラムの改良と分節化を必要としない認識手法

認識に加速度、角速度両方を用いることで認識の精度を向上することが想定される。

また、分節化プログラムを独立させた場合、分節化された運動パターン毎に認識するのではなく、一定の時間幅で強制的に区切った動作をすべてモデルとすることで分節化を必要としない認識手法を試みる。

### 4. リアルタイム認識とモデルの自動作成

リアルタイム分節化と認識を統合し、リアルタイムでの認識が確認できた場合、同様の動作を自動的に学習させることができる。

これとは別に分節化を行わずに認識を行った場合には逐次作成されるモデルをすべてクラスタリングすることでモデルを学習させていく手法についても試みる。

### 5. 複数台のセンサを用いた場合の認識

複数台のセンサを用いて行った実験において、分節点でないと判定された部分に対して動作の分類を行う。

## 本論文に関する業績

### 国際学会

#### **Segmentation of Human Body Movement using Inertial Measurement Unit**

Takashi Aoki, Gentiane Venture, Dana Kulić

Proceedings of IEEE International Conference on Systems, Man, and Cybernetics 2013, pp.1181-1186, Manchester, UK, 13-16 October 2013.

#### **Segmentation of human body motion using multi IMU sensor**

Takashi Aoki, Naoki Doshida, Kazuhiro Kitamura, Gentiane Venture

Proceedings of the ICT International Student Project, 1B2, Tokyo, Japan, 23-24 May 2015.

#### **Segmentation of human upper body movement using multiple IMU sensors**

Takashi Aoki, Jonathan Feng-Shun Lin, Dana Kulić, Gentiane Venture

Proceedings of the 38<sup>th</sup> International Conference of the IEEE Engineering in Medicine and Biology, Orland, USA, 16-20 August 2016.

### 雑誌論文

#### **Segmentation of human upper-body movements using multiple gyro-sensors and still movements**

Takashi Aoki, Jonathan Feng-Shun Lin, Dana Kulić, Gentiane Venture

IEEE Access, 査読中.

### 国内会議

#### **IMU 搭載機器を用いた腕運動のパターン認識**

青木崇, Venture Gentiane, Dana Kulić

第 19 回日本 IFToMM 会議シンポジウム, pp. 33-36, Tokyo, Japan, June 2013.

#### **IMU を用いた人体動作認識**

青木崇, Venture Gentiane, Dana Kulić

DVD Proceedings ROBOMECH2012, 2P-B09, Hamamatsu, Japan, May 2012

#### **Wii コントローラを用いた人体運動のパターン認識**

青木崇, Dana Kulić, Venture Gentiane

DVD Proceedings ROBOMECH2013, 2A-H01, Tsukuba, Japan, May 2013

## 謝辞

本研究及び本論文作成にあたり，終始多大なるご指導，ご助言を賜りました東京農工大学大学院工学府機械システム工学専攻准教授・ベンチャー・ジェンチャン先生に厚く御礼申し上げます。同じく，適宜丁寧なご指導，ご指摘を賜りました，東京農工大学大学院工学府機械システム工学専攻教授・田川泰敬先生に心から御礼申し上げます。

本研究で用いた隠れマルコフモデルによる認識手法に関して基本となるプログラムを提供してくださり，様々なご助言を賜りましたカナダのウォータールー大学 ダナ・クリッチ先生，ジョナサン・リン様ならびに東京大学中村仁彦先生と高野渉先生に深く感謝いたします

IMU による太鼓を叩く実験に際し，ご協力いただきましたフランスのリードラボの J.J. ホクテュリエ博士，実験に協力して下さったミュージシャンであり和太鼓奏者の影山伊作様には，この場をお借りして御礼申し上げます。

ベンチャー研究室，田川研究室の方々には研究室生活を通じて多くのご意見，ご助言をいただき，心から感謝いたします。

## 参考文献

- (1) E. Polak, J. Kulasa, A. Vencesbrito, M. A. Castro and O. Fernandes, "Motion analysis systems as optimization training tools in combat sports and martial arts," *Revista de Artes Marciales Asiáticas*, León, v. 10, n. 2, pp. 105-123, January 2016. ISSN 2174-0747.
- (2) V. Joukov, M. E. Karg and D. Kulić, "Online Tracking of the Lower Body Joint Angles using IMUs for Gait Rehabilitation," *IEEE Engineering in Medicine and Biology Conference*, pp. 2310-2313, 2014.
- (3) G. Venture, K. Ayusawa, Y. Nakamura, "Nakamura-tracking of the Lower Body Joint Angles using IMUs with Realtime Visual Feedback," *Proc. Of the 2009 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp.1627-1632, 2009.
- (4) ベンチャー・ジェンチャン, 鮎澤光, 中村仁彦, "ヒューマノイドロボットの力学同定法を用いた人間の力学パラメータの同定", *ロボット学会 2008-26th RSJ Conference, Kobe, Japan, Sep.9-11, 2008*.
- (5) 松日楽信人, 小川秀樹, 吉見卓, "人と共存する生活支援ロボット", 特集: 130年目の東芝から. 未来へ東芝レビュー, 60, 2005VOL.60 No.7, p.112-115.
- (6) 内閣府共生社会政策統括官, "平成 27 年版 高齢社会白書 (全体版)", <[http://www8.cao.go.jp/kourei/whitepaper/w-2012/zenbun/s1\\_1\\_1\\_02.html](http://www8.cao.go.jp/kourei/whitepaper/w-2012/zenbun/s1_1_1_02.html)>, 2016 年 5 月 16 日.
- (7) 門根秀樹, 中村仁彦, "パターンとの相関と連想記憶に基づく運動パターンの分節化・記憶・抽象化", 第 24 回日本ロボット学会学術講演会, 1D32, 2006
- (8) 稲邑哲也, 中村仁彦, 戸嶋巖樹, 江崎英明, "ミメシス理論に基づく見まね学習とシンボル創発の統合モデル", *日本ロボット学会誌*, Vol.22, No.2, pp.256-263, 2004.
- (9) 高野渉, 山根克, 中村仁彦, "動作パターンの認識・生成に基づく人の動作データベースの設計", *ロボティクス・メカトロニクス講演会'06*, 2A1-E31, 早稲田, 東京, 2006. 5.27-28.
- (10) D. Lee, D. Kulić, Y. Nakamura, "Missing Motion Data Recovery using Factorial Hidden Markov Models", *IEEE International Conference on Robotics and Automation*, pp.1722-1728, 2008.
- (11) 高野渉, 中村仁彦, "統計的相関に基づく動作パターンの分節化", 第 19 回人工知能学

- 会全国大会, 3F1-02, 北九州, 福岡, 2005.6.15-17.
- (12)W. Takano and Y. Nakamura, "Humanoid Robot's Autonomous Acquisition of Proto-Symbols through Motion Segmentation," In IEEE International Conference on Humanoid Robots, pp.425-431, 2006.
- (13)クリッチ・ダナ, 高野渉, 中村仁彦, "逐次記憶化および分類による全身運動知識の自己組織化", JSME Conference on Robotics and Mechatronics, 1P1-G21, 2008.
- (14)D. Kulić, W. Takano, Y. Nakamura, "On-line Segmentation and Clustering from Continuous Observation of Whole Body Motions", IEEE Transactions on Robotics, Vol.25, No.5, pp.1158-1166, 2009.
- (15)D. Kulić, D. Lee, Y. Nakamura, "Whole Body Motion Primitive Segmentation from Monocular Video", IEEE International Conference on Robotics and Automation, pp. 3166-3172, 2009.
- (16)D. Kulić, W. Takano, Y. Nakamura, "Representability of Human Motions by Factorial Hidden Markov Models", IEEE/RSJ International Conference on intelligent Robots and Systems, San Diego, CA, USA, Oct. 29-Nov. 2, 2007
- (17)T. Zhang, M. Karg, J. Lin, D. Kulić, G. Venture, "IMU based Single Stride Identification of Humans," Proc. of the IEEE Int. Symp. on Robot and Human, Interactive Communication, pp. 220-225, Gyeongju, Korea, 2013.
- (18)望月俊克, 原山美知子, 伊藤健太, "遠隔リハビリテーション支援システムマーカレス動画認識による片麻痺機能テスト,"情報処理学会第74回大会, 5ZH-2, pp. 4-933-4-934, 2012.
- (19)白井暁彦, 小坂崇之, くるくる研究室, 木村敬, "WiiRemoteプログラミング", 株式会社オーム社, 2009.
- (20)Pocket-IMU2, < [http://www.gsport.co.jp/p\\_1\\_pocket.html/](http://www.gsport.co.jp/p_1_pocket.html/)> 2016年5月14日
- (21) " — WiiYourself!-gl.tter's native C++ Wiimote library ", < <http://www.google.co.jp/search?q=Wiiyourself&sugexp=chrome,mod=0&sourceid=chrome&ie=UTF-8>>, 2012年8月11日
- (22) "BrainPeek.com", < <http://www.brianpeek.com/page/wiimotelib.aspx>>, 2012年8月11日
- (23)高野渉, 中村仁彦, "統計的相関に基づく動作パターンのリアルタイム教師なし分節化と原始シンボルの自律的獲得", 日本ロボット学会誌, Vol.27, No.9, pp.1046-1057, 2009.
- (24)C.M.ビショップ, "パターン認識と機械学習 上・下", シュプリンガー・ジャパン株式会社, 2008.
- (25)L. R. Rabiner, "A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition," Proceedings of the IEEE vol. 77, Feb., 1989, pp.257-286.
- (26)Kohlmorgen, and S. Lemm, "A Dynamic HMM for On-line Segmentation of Sequential Data," in NIPS 2001: advances in Neural Inf. Processing Systems, T. G. Dietterich, S. Beker, X. Ghahramani, Eds., vol. 14, 2002, pp.793-800.

- (27)D. Kulić, and Y. Nakamura, "Scaffolding on-line segmentation of full body human motion patterns," In Proceeding of the IEEE/RSJ Intrenational Conf.on Int. Robots and Systems, pp.2860-2866, 2008.
- (28)B. Janus, Y. Nakamura, "Unsupervised Probabilistic Segmentation of Motion Data for Mimesis Modeling," IEEE International Conference on Advanced Robotics, 2005, pp. 424-430.
- (29)土支田, "人間とロボットのスムーズなコミュニケーションを実現するためのグラスピング動作の分類", 東京農工大学卒業論文, 2015年3月
- (30)吉井貞熙, "電子情報通信工学シリーズ 音声情報処理", 森北出版株式会社, 1998.
- (31)中川聖一, "確率モデルによる音声認識", 社団法人電子情報通信学会, 1988.
- (32)安藤彰男, "リアルタイム音声認識", 社団法人電子情報通信学会, 2003.
- (33)IMU User Guide rev1.3.pdf, <<http://www.shimmersensing.com/support/wireless-sensor-networks-documentation/>> 2015年2月8日
- (34)中村亨, "身体運動の認識:時間分節化による方法", 計測自動制御学会 第32回知能システムシンポジウム, pp.449-453, 2005
- (35)G. Venture, K. Ayusawa, and Y. Nakamura, "Motion Capture Based Identification of The Human Body International Parameters," International IEEE EMBC, 2008, pp. 4575-4578.
- (36)W. Zeng, "Microsoft Kinect Sensor and Its Effect," IEEE MultiMedia, Multimedia at Work, April, 2012.
- (37)G. Venture, K. Ayusawa, and Y. Nakamura, "Optimal estimation of human body segmentation dynamics using realtime visual feedback," In Proceeding of the 2009 IEEE/RSJ International Conf. on Int. Robots and Sytems, pp.1627-1632, 2009.
- (38)M. Dunbain, and L.Marques, "Robotics for environmental monitoring," IEEE Robotics and Automation Magazine, March, 2012.
- (39)M. Okamura, M. J. Matarić, and H. I. Christensen, "Medical and healthcare robotics," IEEE Robotics and automation magazine, September, 2010.
- (40)J. Broekens, M. Heerink, and H. Rosendal, "Assistive social robots in elderly care: a review," International journal on the fundamental aspects of technology to serve the ageing society, Gerontechnology, 8(2), 94-103, 2009.
- (41)D. Kulić, C. Ott, D. Lee, J. Ishikawa, and Y. Nakamura, "Incremental learning of full body motion primitives and their sequencing through human motion observation," The International Journal of Robotics Research 31(3), pp.330-345, Nov. 2012.
- (42)M. Dunbabin, and L. Marques, "Robotics for Environmental Monitoring," IEEE Robotics and Automation Magazine, March, 2012.
- (43)K. Ayusawa, G. Venture, and Y. Nakamura, "Real-time implementation of physically consistent identification of human body segments," ICRA 2011, pp. 6282-6287,2011.
- (44)T. Aoki, G. Venture, and D. Kulić, "Segmenatation of human body movement using internal

- measurement unit,” IEEE International Conference on systems Man and Cybernetics, SMC2013, pp. 1181-1186, 2013.
- (45)J. F. S. Lin, and D. Kulić, ”Segmenting Human Motion for Automated Rehabilitation Exercise Analysis,” Proceedings of the 2012 34<sup>th</sup> Annual International Conference of the IEEE EMBS, San Diego, California USA, 28 August - 1 September 2012, pp. 2881-2884.
- (46)J. F. S. Lin, and D. Kulić, “Human pose recovery using wireless internal measurement units,” vol. 33, 2012, pp. 2099-2115.
- (47)J. F. S. Lin, V. Joukov and Dana Kulić, “Full-body multi-primitive segmentation using classifiers,” IEEE-RAS International Conference Humanoid Robots 2014, pp. 874-880. November, 2014.
- (48)J. F. S. Lin, V. Joukov, and Dana Kulić, “Human Motion Segmentation by Data Point Classification,” IEEE International Conference EMBC 2014, pp. 9-13. August, 2014.
- (49)H. Tamura, D. Sasajima, K. Tanno, and T. Toyama, “Human Motion Recognition System using Nintendo wii® Remote Controller,” Memoirs of the Faculty of Engineering, Miyazaki University, 37, 2008, pp. 141-146.
- (50)K. Aoki, A. Kimura, M. Mochimaru, J. Ushiba. And Y. Tomita, “Separation of the ground reaction forces of both legs from the resultant force data during double stance phase (Development of the treadmill which can be used for biomechanical analysis),” Transactions of the Japan Society of Mechanical Engineers, No. 07-24, 2007, pp. 311-316.
- (51)K. Ayusawa, G. Venture, and Y. Nakamura, “Identification of Flying Humanoids and Humans,” In IEEE International Conference of Robotics and Automation, 2010, pp. 3715-3720.
- (52)E. Garcia, M. A. Jimenez, P. G. Santos, and Armada, “The Evolution of Robotics Research,” IEEE Robotics and Automation Magazine, March, 2007.
- (53)鮎澤光, ベンチャー・ジェンチャン, 中村仁彦, “ベースリンクの運動方程式を利用した脚型ロボットの最少力学パラメータの同定”, 日本ロボット学会誌, Vol.27, No.9, pp.1066-1077, 2009.
- (54)鮎澤光, ベンチャー・ジェンチャン, 山本江, 中村仁彦, “床反力計に基づくヒューマノイドの全身力学パラメータ同定”, 第13回ロボティクスシンポジウム, 2008.
- (55)堤下裕介, 大井翔, 佐野睦夫, 西口敏司, “遠隔認知リハビリテーションのための支援ロボットと環境認識技術に関する研究～人と生活用品のインタラクションに基づく危険度マップの生成～,” 情報処理学会第75回全国大会, 4U-1, pp. 2-581-2-582, 2013.



## 付録<sup>(30)(31)(32)</sup>

### 付録 A フォワードアルゴリズム (Forward Algorithm)

モデル $\lambda$ に対する計測系列 $\mathbf{O}$ の確率 $P(\mathbf{O}|\lambda)$ の尤度計算に用いられ、モデル $\lambda$ が計測系列モデル $\mathbf{O}$ にどの程度適応しているかを評価する際に用いる。

時刻 $t$ において $\mathbf{o}(t)$ を出力し、状態 $q_i$ にある確率をフォワード変数 $\alpha_i(t)$ と定義する。

$$\alpha_i^*(t) = \begin{cases} \pi_i & t = 0 \\ \sum_{j=1}^N \alpha_j(t-1) a_{ji} b_i(\mathbf{o}(t)) & t > 0 \end{cases} \quad (\text{A.1})$$

$$\alpha_i(t) = C(t) \alpha_i^*(t) \quad (\text{A.2})$$

$$C(t) = \left[ \sum_{i=1}^N \alpha_i^*(t) \right] \quad (\text{A.3})$$

$$\log P(\mathbf{O}|\lambda) = \log \left[ - \sum_{i=1}^N C(t) \right] \quad (\text{A.4})$$

ここで、 $\pi_i$ は初期状態で $i$ にある確率、 $b_i(\mathbf{o}(t))$ は状態 $i$ で記号列 $\mathbf{o}(t)$ を出力する確率、 $C(t)$ はアンダーフローを回避するためのスケーリング係数である。

Viterbi アルゴリズム(Viterbi Algorithm)はモデル $\lambda$ の最適な状態系列 $\mathbf{Q} = (q_1 q_2 \cdots q_T)$ を検索する。計測系列 $\mathbf{O}$ がどの状態系列 $\mathbf{Q}$ から生成されたと考えられるかを決定する。

### 付録 B Baum-Welch アルゴリズム

Baum-Welch アルゴリズムは $P(\mathbf{O}|\lambda)$ の計測系列 $\mathbf{O}$ を生成する確率を最大とするようなモデルパラメータ $\mathbf{A} = a_{ij}$ ,  $\mathbf{B} = b_{ij}$ ,  $\Pi$ の最適化を行う。

時刻 $t$ において状態 $q_i$ にあって計測系列 $\mathbf{o}(t+1)$ を出力する確率をバックワード変数 $\beta_i(t)$ と定義する。

E-step(Expectation-step)

$$\beta_i^*(T) = \begin{cases} 1 & q_i \in F \\ 0 & q_i \notin F \end{cases} \quad t = 0$$

$$\beta_i^*(t) = \begin{cases} 1 & t = 0 \\ \sum_{j=1}^N a_{ij} b_j(\mathbf{o}(t+1)) \beta_j(t+1) & t > 0 \end{cases} \quad (\text{C.1})$$

$$\beta_i(t) = C(t) \beta_i^*(t) \quad (\text{C.2})$$

$$C(t) = \left[ \sum_{i=1}^N \beta_i^*(t) \right] \quad (\text{C.3})$$

$$\log P(\mathbf{O}|\lambda) = \log \left[ - \sum_{i=1}^N C(t) \right] \quad (\text{C.4})$$

ここで、時刻 $t$ において状態 $q_i$ に存在し、時刻 $t+1$ において状態 $q_j$ に遷移する確率を $\xi_{ij}(t)$ と定義する。

$$\begin{aligned} \xi_{ij}(t) &= P(q(t) = i, q(t+1) = j | \mathbf{O}, \lambda) \\ &= \frac{P(q(t) = i | q(t+1) = j, \mathbf{O} | \lambda)}{P(\mathbf{O} | \lambda)} \\ &= \frac{\alpha_i(t) a_{ij} b_j(\mathbf{o}(t+1)) \beta_j(t+1)}{P(\mathbf{O} | \lambda)} \\ &= \frac{\alpha_i(t) a_{ij} b_j(\mathbf{o}(t+1)) \beta_j(t+1)}{\sum_{i=1}^N \sum_{j=1}^N \alpha_i(t) a_{ij} b_j(\mathbf{o}(t+1)) \beta_j(t+1)} \end{aligned} \quad (\text{A.5})$$

ここでモデルと計測系列全体が与えられたときに時刻 $t$ で状態 $q_i$ に存在する確率 $\gamma_i(t)$ と定義する。 $\gamma_i(t)$ は $\xi_{ij}(t)$ を $q_j$ について総和したものと考えられる。

$$\gamma_i(t) = \sum_{j=1}^N \xi_{ij}(t)$$

$$\gamma_{ij}(t) = \frac{\alpha_i(t) \beta_i(t+1)}{\sum_{j=1}^N \alpha_j(t) \beta_j(t)}$$

ここで,

$\sum_{t=1}^{T-1} \gamma_i(t)$  :  $\mathbf{O}$  において状態  $i$  から遷移する回数の期待値  
 $\sum_{t=1}^{T-1} \xi_{ij}(t)$  :  $\mathbf{O}$  において状態  $i$  から状態  $j$  へ遷移する回数の期待値

M-step (Maximization-step)

$$\begin{aligned}\hat{\pi}_i &= \gamma_i(0) = \sum_{j=1}^N \xi_{ij}(0) \\ \hat{a}_{ij}(t) &= \frac{\sum_{t=0}^{T-1} \xi_{ij}(t)}{\sum_{t=0}^{T-1} \gamma_i(t)} \\ \hat{b}_{il}(t) &= \frac{\sum_{t=0}^T \xi_{il}(t)}{\sum_{t=0}^T \gamma_i(t)} \\ \mu_{il}(t) &= \frac{\sum_{t=0}^T \gamma_{ij}(t) o(t)}{\sum_{t=0}^T \gamma_{il}(t)} \\ \Sigma_{ij} &= \frac{\sum_{t=0}^T \gamma_{il}(o(t) - \mu_{il})(o(t) - \mu_{il})^T}{\sum_{t=0}^T \gamma_{il}(t)}\end{aligned}$$

以上の計算より, それぞれが収束するまで計算を繰り返し, HMM の学習を行う.