

Kinect を用いた単調作業における特徴部位の推定 Determining Characteristic Joints during Monotonous Tasks with Motion Sensor

岡村 瞬[†]問谷 洋平[‡]梶原 祐輔[†]島川 博光[†]

Shun Okamura

Yohei Tontani

Yusuke Kajiwara

Hiromitsu Shimakawa

1. はじめに

製造業における作業現場では、作業者の怪我や製品の不良などといったヒューマンエラーの問題がある。作業現場での作業者の怪我によって最悪の場合、作業者は命を落とす。また製品の不良は顧客からの信頼を失ったり、納品数の変動による再生産による余計なコストがかかる。大工場で推進されている自動化はヒューマンエラーをなくすことに貢献するが、小工場には高価過ぎる。また、少量多品種の製品のために作業が頻繁に変わる製造ラインでは、工場の自動化は実現不可能である。

このようなヒューマンエラーを解決するため、作業現場では指差し確認 [1] や定期的な休憩などの対策がとられている。しかし、作業者ごとに集中力の持続時間は異なるため、このような画一的な対策では対応することが難しい。この個人差を考慮するには、個人に合わせた対策をする必要がある。作業者の集中力を測定できれば、集中力が低下した作業者に対して休憩をはさむなどの個人に合わせた対策をたてられる。このような個人差を考慮した、集中力の低下を発見する方法は、高い生産性をもった安全な生産ラインをつくるのに不可欠である。

より柔軟な対策をたてるため我々は [2] に示すような手法を研究してきた。この研究では、加速度センサを使って作業者の頭と右手首の集中時の動作を取得することで作業者の集中力を測定する。しかし、この手法では加速度センサ取り付け部位の有用性を考慮していない。他の部位で測定することで、より集中力を測定できる作業者の存在が考えられる。そこで、他の部位を考慮するために加速度センサの取り付け部位を推定する研究が必要とされる。加速度センサの取り付け部位を推定できれば、各作業者に適したタイミングで休憩をとるなどの対策を与える。本論文では、単調作業における作業者の単調作業動作を分析することで、着目すべき重要部位を推定する手法を提案する。本手法では画像処理に基づくモーションセンサを用いて着目すべき重要部位を推定する。モーションセンサによって、集中時と非集中時における作業者の全身の部位の動作を取得する。機械学習を用いて集中時と非集中時の動作の違いから重要部位を推定する。本手法は以下のような特徴を持つ。

- モーションセンサを用いることで、作業者の全身の部位の動作を測定する。
- 全身の部位の動作に対して機械学習を用いて、自動的に重要部位を推定する。

本手法の有用性を示すために、現場での作業を模した作業を実装し実験した。実験ではモーションセンサから取得した被験者の各部位の動作を用いて重要部位を推定することに注力した。その結果、ほぼすべての被験者に対して加速度センサ取り付け部位を推定できた。

[†]立命館大学情報理工学部

[‡]立命館大学大学院理工学研究科

2. 単調作業の現状と問題点

2.1 ライン生産方式

現在、製造業の生産方式の1つにライン生産方式がある。ライン生産方式では1つの製品を作るために、ベルトコンベアを用いた流れ作業を行う方式である。このライン生産方式では作業者一人一人は単調作業を繰り返すことで、作業者に負担がかかる。それにより、作業者の集中力低下が起こり作業中の怪我や失敗につながる。この作業者の集中力低下を防ぐために現場の工場では指差し確認 [1] や定期的な休憩をはさむなどの対策がある。しかし、作業者ごとに集中力には個人差が見られるため画一的な対策では対応することが難しい。作業者ごとの集中力低下をリアルタイムで発見することで、個人に合わせた対策をたてられるので、個人ご作業者の怪我・ミスを防げる。ゆえに集中力低下を発見する方法は高い生産性をもった安全な生産ラインをつくるのに不可欠である。

2.2 基礎研究

より柔軟な対策をたてるため我々は単調作業時の作業者に加速度センサを頭部と右手首に取り付け、頭部と右手首の動きを観測することで作業者の集中力を測定するシステムを提案した [2]。この手法は作業者が集中している時の動きを事前に学習させる。その事前学習した動きと作業時に実際に取得した動作の差分によって作業者の集中力を測定する。この手法によって加速度センサを取り付けた作業者の動作から作業者が集中しているかがわかる。それにより、作業者一人ひとりに対して適切なタイミングで休憩を挟むなどの個人に合わせた対策をたてることのできるため有用である。しかしこの研究では頭部と右手首以外の加速度センサ取り付け部位の有用性を考慮していない。また、他の部位で測定するほうがより集中力を測定できる作業者もいることが考えられる。そこで加速度センサの取り付け部位を推定する研究が必要とされている。

2.3 既存研究

体につけた加速度センサでユーザの精神的状態を把握する研究が多くある。研究 [3] は加速度センサを子供たちの腰につけて、加速度センサから取れるデータを用いて子供の集団行動を測定する。それによって、子供の交友関係を分析することで子供の健全な発達・成長に役立てることができるという研究である。また研究 [4] は加速度センサとカメラを用いて保育者が多くの子供に絵本を読んで聞かせている間の子供の振り返り動作などを観測する。それによって子供の集中度を測定し、保育者に知らせることで絵本の読み聞かせへの興味を子供にもたせる研究である。しかし、部位について考慮していないので最良な位置である保証がない。よって、本研究ではセンサを取り付けるうえで最良の部位を推定する手法を提案する。

3. Kinect を用いた特徴部位の推定

3.1 全体像

本論文では単調作業時に作業員からモーションセンサ Kinect を用いて作業員の単調作業動作を取得することで、特徴部位を推定する手法を推定する。本研究では、特徴部位を単調作業時において作業員が集中しているか集中していないかを判別できる体の部位と定義する。人によってあるいは作業によってどの部位が特徴部位か不明なため体全体の動きを観測する必要がある。そこで体全体の部位に総当たりで加速度センサをつけて調べる方法が考えられる。しかし、同時に体全体の部位の動きを接触型のセンサで調べようとすると作業員に大きな負担となる。本手法では単調作業時における作業員の多数の部位に同時に着目できる非接触型モーションセンサ Kinect を用いる。

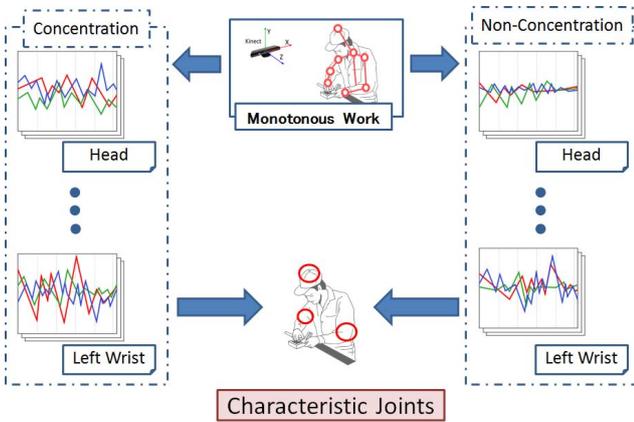


図 1: 手法概要図

図 1 に本手法の概要を示す。Kinect を用いて作業員個人ごとに集中時と非集中時の作業員の部位の位置を取得する。Kinect は作業員に負担をかけずに作業員の全身の部位の位置を取得できるため、効果的に特徴部位を推定できる。特徴部位の発見は、長時間の単調作業時に作業員の特徴部位の動作を観測することで作業員の集中を判定することを可能にする。それにより、個々の作業員に応じてヒューマンエラーを防止できる。本研究ではこの特徴部位を推定することに注力する。

3.2 Kinect を用いた動作データの取得

本手法では Kinect を用いて特徴部位を推定する。Kinect は画像の深度を測定することで人間の骨格を認識し、全身の部位の位置を測定できる安価な非接触型モーションセンサとして用いることができる。図 2 に Kinect の映像を示す。図 2 の黒点が人間の各部位である。Kinect は図 2 の全身 20 個ある黒点すべての三方向の位置を同時に測定できる。三方向は図 2 の水平方向に対応 x 、鉛直方向に対応する y 、そして奥行きに対応する z で構成される。作業員が Kinect の前で単調作業を繰り返すときに作業員の各部位の位置を取得する。また、本手法では流れ作業で行う作業の内ベルトコンベアで流れてきた製品を作り再びベルトコンベアに流すまでを一作業と定義する。Kinect で取得した一作業ごとの各部位の位置情報を一動作データとする。つまり一作業分において一動

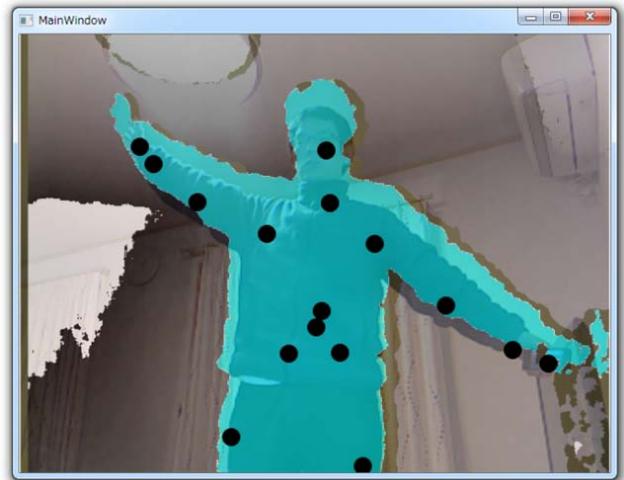


図 2: Kinect の映像例

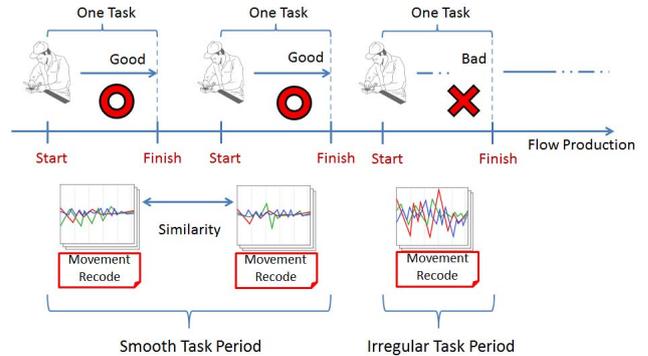


図 3: 規則的な動作周期

作データは測定した部位の数だけ得られる。この各部位ごとの一動作データを作業員が集中しているときと集中していないときの 2 クラスに分類する。

3.3 特徴抽出

本手法では、ライン生産で過度に長い時間の単調作業時の繰り返し動作が作業員の集中力を奪うという事実に着目して特徴部位を推定する。単調作業を繰り返して作業員が集中するにつれ、図 3 に示すように一作業ごとの動作が似るため作業員の動作に一定の作業周期が生まれる。一方、作業員の集中力が低下しているときには作業に関係ない動作や各動作そのもののペースの乱れのためその作業周期が乱れる。動作データの周期性を調べれば、集中力の低下を検知できる。そこで本手法ではフーリエ変換を用いて各部位の位置の一動作データにおける周期を抽出する。集中しているときと集中していないときの動作データをフーリエ変換する。本研究では、一動作データにおける 1 部位の位置の推移をフーリエ変換した結果出力されるデータを TaskSpectrum と定義する。フーリエ変換の結果、一作業において TaskSpectrum が作業員の部位の数だけ得られる。ここで得た多量の TaskSpectrum を機械学習の入力として用いる。機械学習では、学習することで集中時と非集中時の TaskSpectrum を分類するソフトウェアモジュールを作る。新たに TaskSpectrum

		X-axis Frequency			Y-axis Frequency			Z-axis Frequency		
CLASS		0.0	0.1	...	0.0	0.1	...	0.0	0.1	...
Concentration	1	0.000	6.659	...	5.126	1.790	...	7.459	1.616	...
	2	1.560	5.249	...	5.051	6.333	...	7.854	0.413	...
	3	2.967	7.212	...	4.833	7.444	...	6.671	6.035	...
Task Spectrum		⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
Non-Concentration	2	6.656	1.088	...	1.661	0.373	...	8.417	5.137	...
	3	1.323	2.996	...	0.344	1.911	...	5.162	3.505	...
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮

図4: 入力データ

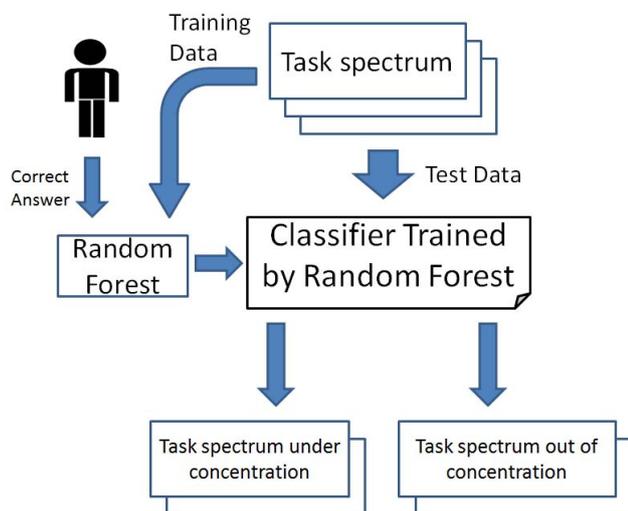


図5: RandomForestの概要

をこのモジュールに与えることで、TaskSpectrum が集中時あるいは非集中時のどちらに属するかを自動的に識別する。集中時と非集中時の TaskSpectrum の違いが大きければ、より集中時と非集中時の分類が容易になり特徴部位を推定できる。また、作業によって特徴部位の位置は様々であるので各作業者の全身の部位から特徴部位を推定する必要がある。

3.4 特徴部位の推定

本手法では、機械学習アルゴリズムを用いて各部位における多数の TaskSpectrum を機械学習させて作業者の特徴部位を推定する。機械学習を用いることで、人間が意図していない部位を特徴部位として推定できる。さまざまな機械学習アルゴリズムがあるが本手法では RandomForest を用いる。その理由として RandomForest には他の機械学習アルゴリズムにはない説明変数をスコアリングすることによって、変数の重要度に重みをつけられる。このスコアリング結果を考察や解析に用いることができる。

本手法では図4のように RandomForest に用いる説明

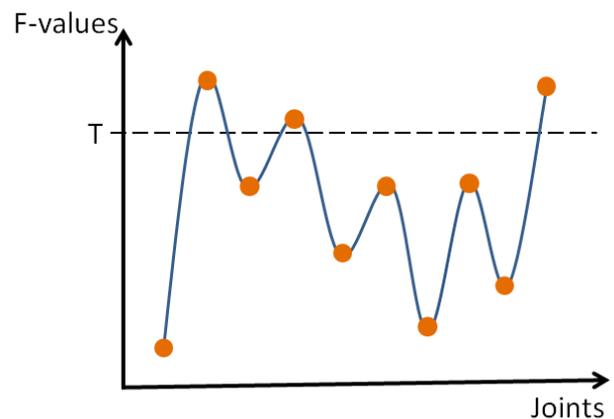


図6: 各部位のF値

変数として、三方向それぞれの周波数に対する様々な集中時と非集中時での振幅を用いる。図5に示されるように、多量の集中時と非集中時の TaskSpectrum を用いて RandomForest を用いて分類器に学習させる。学習した分類器に TaskSpectrum を入力すると、事前に学習した TaskSpectrum との類似性から入力した TaskSpectrum が集中時か非集中時のどちらに属するかを自動判別する。特定の部位についてこの集中時と非集中時の正解率が高ければ、その部位は集中時の TaskSpectrum と非集中時の TaskSpectrum を他の部位より正確に区別する。よって特徴部位は集中時と非集中時の正解率が共に高い部位である。

一般に機械学習による分類問題では汎化性能を考慮する必要がある。汎化性能が高いならば、再現率と適合率の両方が高い。本手法は図6に示すように、特徴部位を推定するために各部位に対して再現率と適合率から F 値を計算する。本手法では F 値がある閾値 T より高い部位が特徴部位となる。

4. 実験

4.1 実験目的

本手法の有用性を確かめるために本実験において特徴部位が推定できるかを検証する。本研究の目的として単調作業における作業者の特徴部位を推定することを掲げている。作業者の多数の部位から得た作業周期によって学習した分類器を用いて F 値を計算する。本手法が作業周期を集中時と非集中時に分類するためにより効果的な部位の推定を検証した。

4.2 実験環境

本実験は20代男性15名、20代女性2名、計17名を被験者とする。本実験において、被験者はタブレットPC上に表示された円を10秒以内になぞる。この作業は実際の作業現場でのねじ巻き動作やバルブを回すような振幅動作の単調作業を模した作業[2]です。本実験で用いたタブレットPCの画面を図7に示す。左上の二種類の色の四角形は、作業の成功・失敗を示す。このシステムにおいて一作業はタブレットPC上の円を描き始めてから一周円をなぞるまでである。図7の画面上部のピンクラインが時間制限となっており、1秒ごとにこのライン

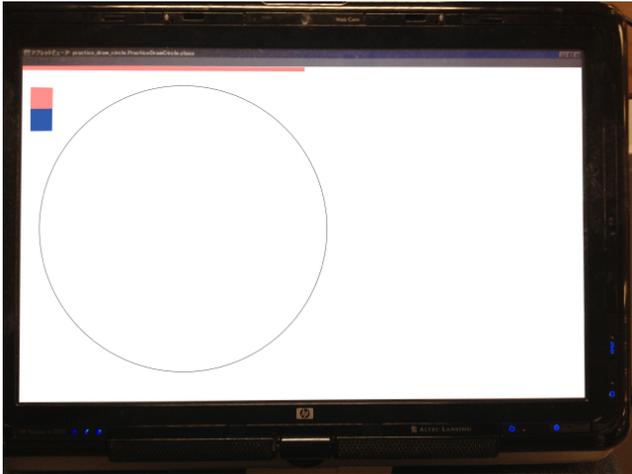


図 7: タブレット PC の画面

が短くなる。本実験では一作業ごとの時間制限を 10 秒に設定している。また本システムではタブレット PC 上に描かれた円からはみ出したときと時間切れの場合作業失敗と判定する。また四角の上部は円を一周したとき色がピンクから青に変わる。このタブレット PC では円の中心からペンが接地した点との距離によって被験者が描いた円のズレを計測し、その値の合計値を作業の作業成果物として用いる。一作業において円のズレの値が少なければより良質な作業成果物、大きければ悪質な作業成果物とする。作業成果物の概要を図 8 に示す。また被験者は Kinect によって作業中各部位の動作を測定される。本実験では、座っている作業のため被験者の上半身のみ 10 部位を考慮する。Kinect は深度カメラであるため、部位の重なりによる死角を考慮しなければならない。そこで本研究では被験者の前方 140cm、高さ 41.5cm に Kinect を設置し Kinect の角度を水平から 10 度下げて上方から被験者の動作を測定する。しかし、斜めから測定すると水平状態の Kinect の計測軸から y 軸と z 軸は 10 度分ずれるので以下の式を用いて軸変換をした。

- $y = z' \sin 10 + y' \cos 10$
- $z = z' \cos 10 - y' \sin 10$

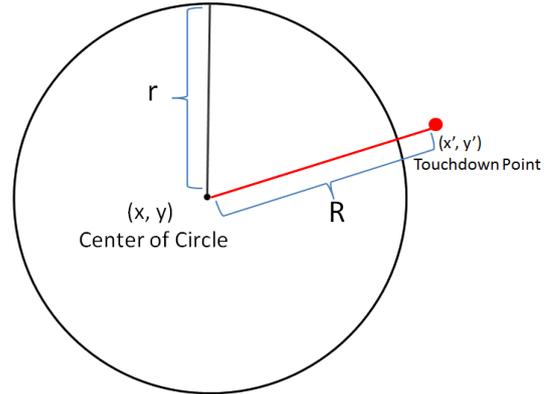
z, y が水平状態の Kinect の計測軸である。

4.3 実験手順

4.2 で述べた実験環境において被験者がする実験手順を述べる。まず被験者は机の上に置かれたタブレット PC の前に座る。その際用いる椅子は被験者自ら高さを調節可能なものを用いた。その後十分な練習をさせて実験を開始する。単調作業の繰り返しを測定するため、被験者には円をなぞる作業を 200 回繰り返す。

4.4 実験結果

本実験では 1 被験者につき 10 部位の動作が測定される。この 10 部位それぞれに対して RandomForest を用いた。本実験で用いた RandomForest の入力データは、作業成果物の出来がもっとも良かった上位 30 回分と作業成果物の出来が悪かった下位 30 回分の合計 60 回分



$$\text{performance record} = |\sqrt{(x-x')^2 + (y-y')^2} - r|$$

(R - r)

図 8: 作業成果物の概要

のタスクスペクトルを用いた。この上位 30 回分のデータを集中時における正解データ、下位 30 回分のデータを非集中時における正解データとする。被験者の各部位ごとの 60 回分のタスクスペクトルに対して、テスト用データ 10 回分、学習用データ 50 回分として 6 クロスバリデーションを用いた。テスト用データと学習用データに含まれる集中時と非集中時のデータの個数は五分五分とする。

本実験では、このシステムがどれくらい分類できているかを集中時と非集中時において考慮する。そこで集中時における適合率とは、集中時と非集中時の合計 60 回分ある全体のデータからシステムが集中時と分類した数の内、集中時の正解データが含まれている割合である。また、集中時における再現率とは集中時の合計 30 回分あるデータ数の内、システムが集中時のデータと分類した数が含まれている割合である。非集中時においても同様である。この適合率と再現率を用いた出力結果の F 値をまとめた表 1 に示す。作業員一人一人の特徴部位は異なる結果だった。この結果作業員一人一人に応じた特徴部位を推定する本手法は有効である。

5. 考察

5.1 クラスタ分類

実験結果は特徴部位を特定するために作業員一人一人に対して繰り返し作業をする学習のための実験の必要があることを意味する。さらに、作業は様々な種類があり、その作業ごとに作業員は学習をする必要があるため作業員一人一人に実験をしてもらうのは大変な労力である。そこで特徴部位を見つける、より簡易な方法を用意すべきである。目視による分析では腕だけで円を描くタイプ、腕と体が連動して円を描くタイプなどのタイプがあることがわかってきた。例えば、集中時に体幹がゆれていないが非集中時に体幹がゆれる被験者がいた。このような被験者は体の全部位に特徴が出ていた。複数の被験者は特徴部位が体のどの部位に多いかという点で類似性をもつと考えられる。事前に集中時と非集中時の体の動きの違いが似ている作業員を分類できていれば、各作業員が

表 1: F 値とクラスタ

Joints	Cluster Number Class	1			2			3					4						
		A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	
HandLeft	Concentration	.687	.542	.516	.759	.517	.492	.475	.596	.413	.525	.509	.610	.508	.615	.596	.656	.509	
	Non-concentration	.604	.557	.483	.774	.548	.475	.492	.635	.351	.508	.585	.623	.456	.545	.635	.644	.585	
WristLeft	Concentration	.625	.702	.655	.780	.533	.508	.483	.571	.467	.500	.600	.536	.618	.557	.557	.625	.431	
	Non-concentration	.571	.730	.677	.787	.533	.456	.516	.526	.467	.429	.600	.594	.500	.542	.542	.571	.580	
ElbowLeft	Concentration	.635	.556	.754	.519	.406	.429	.516	.500	.459	.627	.491	.491	.476	.523	.688	.500	.351	
	Non-concentration	.596	.636	.746	.606	.321	.500	.483	.563	.441	.528	.540	.540	.421	.436	.643	.563	.413	
ShoulderLeft	Concentration	.667	.567	.646	.552	.590	.429	.533	.462	.525	.473	.492	.381	.459	.531	.500	.576	.667	
	Non-concentration	.667	.567	.582	.581	.576	.500	.533	.588	.508	.554	.475	.316	.441	.464	.500	.590	.632	
ShoulderCenter	Concentration	.677	.526	.452	.567	.508	.370	.613	.426	.571	.478	.475	.429	.700	.492	.475	.594	.613	
	Non-concentration	.655	.571	.414	.567	.525	.485	.586	.630	.625	.340	.492	.500	.700	.400	.492	.536	.586	
Head	Concentration	.627	.433	.540	.509	.545	.393	.585	.440	.545	.441	.571	.421	.448	.459	.426	.433	.613	
	Non-concentration	.528	.433	.491	.585	.615	.469	.509	.600	.615	.459	.526	.476	.484	.441	.407	.433	.586	
HandRight	Concentration	.636	.698	.656	.786	.407	.467	.552	.540	.508	.567	.491	.333	.567	.431	.545	.493	.491	
	Non-concentration	.556	.667	.607	.813	.426	.467	.581	.491	.525	.567	.540	.455	.453	.327	.444	.314	.540	
WristRight	Concentration	.738	.600	.646	.793	.381	.179	.586	.526	.557	.551	.436	.154	.554	.531	.533	.533	.340	
	Non-concentration	.691	.600	.582	.806	.316	.281	.613	.571	.542	.392	.523	.353	.473	.464	.533	.533	.478	
ElbowRight	Concentration	.781	.571	.633	.586	.606	.621	.667	.582	.623	.563	.509	.593	.500	.563	.457	.596	.484	
	Non-concentration	.750	.526	.633	.613	.519	.645	.632	.646	.610	.500	.585	.667	.500	.500	.240	.635	.448	
ShoulderRight	Concentration	.667	.536	.557	.623	.554	.373	.656	.596	.581	.379	.533	.367	.475	.400	.357	.576	.373	
	Non-concentration	.698	.594	.542	.610	.473	.393	.644	.635	.552	.419	.533	.367	.492	.492	.438	.590	.393	

どのグループに属しているかを判断することにより、特徴部位を決定できる。そこで作業者のタイプを分類しまとめることが考えられる。本実験で得た F 値の表を元にクラスタ分類をした。

- クラスタ 3 では作業者の右側と左側の部位に特徴がある。
- クラスタ 4 では作業者の右側に特徴がある。

これにより特徴部位の傾向を 4 つまで絞ることが出来た。作業者は彼らの特徴部位を正確に同定する実験よりも、はるかに少ないタスクでグループへ分類できる。この 4 つのタイプの作業者を見た目で判断できる手法をつくれれば、作業者ごとに実験する必要なくなる。

5.2 重要変数度

作業者の見た目による判断を補助するため Random-Forest のスコアリング機能を使って、変数重要度を算出した。各クラスタの各部位について上位 3 つの変数重要度を表 2 に示す。その結果、変数重要度が高い部位というのは F 値の高い部位であるということが分かる。また各クラスタは以下の特徴があると考えられる。

- クラスタ 1 では、左側の部位において低い周波数の重要度が高いため、体の左側の部位の止まっているあるいはゆっくりとした動きが集中と非集中を区別するのに有効である。作業を実施している右側の部位では、重要度の高い周波数に幅が見られる。得意な部分の作業は速く、作業者にとって苦手な部分の作業ではゆっくり作業していることが考えられる。
- クラスタ 2 ではクラスタ 1 と比べて全身における低い周波数の重要度が高いので、集中時には全身をゆっくり動かして非集中時には左手首や右肩に動作のぶれが生じることが考えられる。
- クラスタ 3 では全身の部位で重要度の高い周波数に幅が見られる。集中している時には集中時と非集中時において全身がよく揺れるということが考えられる。
- クラスタ 4 では左側と頭部に着目すると重要度の高い周波数の差が大きい。集中時には安定したゆった

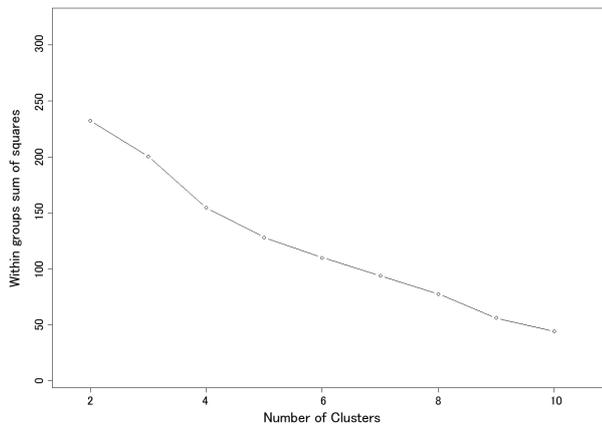


図 9: クラスタ数とグループ内距離の平方和

図 9 にグループ内距離の平方和とクラスタ数の関係を示すグラフを示す。グループ内距離の平方和が小さくなるということは、グループ内に似た要素が集ったことを示す。グループ数を多くすればするほど平方和は小さくなる。一方でグループの数が増えれば増えるほど、作業者が属するグループを決定するのは難しくなる。適切なバランスを取るため本考察では、グループ内距離の平方和が急に下がった直後であるクラスタ数 4 を用いた。分類結果の F 値の表を表 5. 2 に示す。F 値が 0. 6 位上の部位は色付けされている。表 1 は以下の 4 つのクラスタがあることを示している。

- クラスタ 1 は体の全部位に特徴がある。
- クラスタ 2 では作業者の左側の部位に特徴がある。

表 2: 変数重要度

Joints	Ranking	Cluster Number											
		1			2			3			4		
		Importance measures	Axis	Frequency									
HandLeft	1	0.420	z	0.0	0.260	y	0.0	0.111	y	3.5	0.110	y	11.1
	2	0.400	x	7.7	0.225	x	0.0	0.101	z	4.8	0.107	x	5.0
	3	0.397	x	6.4	0.217	z	0.0	0.099	y	0.0	0.100	y	0.1
WristLeft	1	0.503	y	0.0	0.509	z	0.0	0.137	y	3.5	0.113	x	11.7
	2	0.420	z	0.0	0.322	y	0.0	0.117	z	0.8	0.106	y	0.3
	3	0.320	z	2.3	0.167	x	5.5	0.113	y	0.2	0.105	y	0.0
ElbowLeft	1	0.370	z	0.0	0.649	y	0.0	0.108	y	1.5	0.115	x	0.0
	2	0.337	x	0.3	0.461	z	0.0	0.108	z	12.3	0.104	z	11.5
	3	0.304	y	0.0	0.239	z	0.1	0.107	x	6.5	0.101	y	0.0
ShoulderLeft	1	0.511	x	0.3	0.538	z	0.0	0.111	y	0.4	0.169	z	0.0
	2	0.410	y	0.0	0.486	y	0.0	0.108	x	0.0	0.116	x	0.1
	3	0.361	x	0.2	0.452	x	0.0	0.105	y	13.1	0.113	x	0.0
ShoulderCenter	1	0.478	z	0.0	0.474	x	0.0	0.119	y	1.1	0.119	z	0.0
	2	0.339	y	0.3	0.257	z	0.0	0.115	x	0.3	0.102	x	3.2
	3	0.333	x	0.0	0.234	z	0.1	0.108	x	9.7	0.102	x	1.4
Head	1	0.473	x	0.2	0.389	x	0.0	0.117	z	4.5	0.157	x	0.1
	2	0.471	y	1.4	0.231	z	0.0	0.116	z	1.5	0.121	z	1.8
	3	0.396	z	0.0	0.195	y	0.0	0.107	x	8.4	0.106	z	15.2
HandRight	1	0.575	x	0.0	0.314	z	0.2	0.140	x	0.0	0.177	z	0.1
	2	0.286	y	16.4	0.251	y	0.0	0.121	z	0.4	0.129	y	0.1
	3	0.260	y	2.0	0.174	x	0.2	0.112	y	7.9	0.096	x	0.2
WristRight	1	0.556	y	13.2	0.253	x	0.2	0.127	y	0.2	0.127	x	0.0
	2	0.493	y	11.0	0.211	z	9.2	0.121	x	0.0	0.116	z	0.1
	3	0.410	y	6.5	0.191	x	0.5	0.115	x	6.5	0.111	x	16.5
ElbowRight	1	0.368	z	2.4	0.267	y	0.0	0.131	z	6.4	0.134	z	0.1
	2	0.349	y	5.8	0.215	x	8.1	0.125	z	3.9	0.129	y	0.2
	3	0.336	y	2.3	0.192	z	0.1	0.124	y	11.4	0.110	x	0.1
ShoulderRight	1	0.488	x	8.8	0.291	x	0.0	0.122	y	0.2	0.142	z	0.0
	2	0.393	y	0.0	0.155	z	3.6	0.115	y	0.0	0.132	x	0.0
	3	0.332	y	1.5	0.144	z	0.0	0.107	y	0.1	0.117	x	0.1

りとした動きだが、非集中時には小刻みなゆれが出ることが考えられる。

以上の特徴から作業者の観察を通して特徴部位が推定できることを示唆している。

6. おわりに

作業には集中している時と集中していない時で異なる動きをする部位があると想定される。特徴部位に加速度センサを取り付けることで、ヒューマンエラーを未然に防止できる。本論文では、単調作業における作業者からモーションセンサ Kinect を用いて特徴部位を推定する手法を提案した。

本手法では Kinect で作業者の動作を測定することで作業者の動作を取得する。取得した集中時と非集中時における動作データをフーリエ変換することで、集中時と非集中時における周期データを得る。集中時と非集中時における周期データを学習器 RandomForest にかけることで学習分類する。集中時と非集中時の周期データの差分によって特徴部位を推定する。本手法の有用性を確認するために、本手法で特徴部位を推定できるか検証する実験をした。

実験では、Kinect の前で作業者にタブレット PC に描かれた円をなぞる作業を繰り返してもらった。ここで得た作業成果物を用いて作業者の動作データを集中時と非集中時に切り分けた。この二種類の動作データに対して本手法を適用することで作業者の各部位の F 値を算出した。

その結果すべての作業者に対して特徴部位が存在した。これによってすべての作業者に対して特徴部位を推定できた。

参考文献

- [1] K.Shinohara, K.Morimoto, T.Kubota ; "The effect of "Finger-pointing and Call" on orientation of visual attention" (in Japanese). The Japanese journal of ergonomics, 45(1), 54-57 (2009)
- [2] Y.Tontani, Y.Kajiwara, F.Harada, H.Simakawa ; "Judging Working Rhythm from Body Movement to Prevent Human Errors". Proc. of the 12th International Conference on Telecommunications and Informatics, pp.127-132(Sep.16-19, 2013, Baltimore, US)
- [3] K.Kousaka, K.Imaki, M.Shibata, H.Haga, K.Shigeo ; "Classification of Children's Group Activity from Acceleration Data by using Wavelet Transformation"(in Japanese). UBI, 2009-UBI-22(13), 1-8 (2009)
- [4] S.Kaneda, K.Kosaka, K.Imaki, T.Mitsumoto, K.Shintani, A.Kono ; "A Concentration Analysis Approach for Storytelling using Stereo Cameras and Accelerometers" (in Japanese). IPSJ SIGCE, 2010-CE-104(2), 1-8 (2010)
- [5] Breiman, Leo ; "Random Forests". Machine Learning, 45(1), 5-32 (2001)
- [6] J.McQueen ; "Some methods for classification and analysis of multivariate observations". In Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability, pp.281-297 (1967)