

博士（工学）学位論文

異常検知手法を用いた作業姿勢や動作の人間工学評価

2021年3月

平内 和樹

東京都立大学大学院 システムデザイン研究科

指導教員 瀬尾明彦 教授

目次

第 1 章	緒論	1
1.1	研究背景.....	1
1.1.1	機械の自動化に伴う人間の作業の変化.....	1
1.1.2	様々な人間工学的作業評価手法.....	2
1.1.3	機械学習・コンピュータビジョンの応用.....	16
1.1.4	異常検知手法.....	20
1.2	研究目的.....	29
1.3	本論文の構成.....	30
第 2 章	静止姿勢を対象とした異常検知手法を用いた作業姿勢評価： 身体近傍でのねじ締め作業を対象とした One-Class Support Vector Machine の有用性の検証	31
2.1	緒論.....	31
2.2	理論.....	32
2.2.1	One-Class Support Vector Machine の概要.....	32
2.2.2	作業姿勢の分類への応用.....	33
2.2.3	One-class Support Vector Machine のハイパーパラメータの設定.....	36
2.3	実験方法.....	37
2.3.1	被験者.....	37
2.3.2	実験条件.....	37
2.3.3	実験手順.....	38
2.3.4	計測項目および解析方法.....	38
2.4	結果.....	40
2.4.1	関節角度.....	40
2.4.2	関節トルク比.....	40
2.4.3	主観評価.....	42
2.4.4	One-Class SVM による姿勢の分類結果.....	42
2.5	考察.....	45
2.5.1	作業条件と姿勢による比較.....	45
2.5.2	部位ごとの検出回数の比較.....	46
2.5.3	外れ値の条件の妥当性の検証.....	47
2.6	小括.....	47

第 3 章	静止姿勢を対象とした異常検知手法を用いた作業姿勢評価： 障害物回避を伴うリーチ作業を対象とした One-Class Support Vector Machine の有用性の検証	49
3.1	緒論	49
3.2	実験方法	49
3.2.1	被験者	49
3.2.2	実験条件	50
3.2.3	実験手順	50
3.2.4	計測項目および解析方法	51
3.3	結果	52
3.3.1	関節角度	52
3.3.2	主観評価	52
3.3.3	姿勢の異常率	53
3.4	考察	53
3.5	小括	55
第 4 章	時系列データを対象とした異常検知手法を用いた作業動作評価： 特異スペクトル変換を用いた突発的な作業姿勢の変化の検出	57
4.1	緒論	57
4.2	理論	58
4.2.1	特異スペクトル変換の概要	58
4.2.2	パラメータ選択	59
4.3	実験方法	60
4.3.1	被験者	60
4.3.2	実験条件	60
4.3.3	実験手順	61
4.3.4	測定項目と解析方法	61
4.4	結果	63
4.4.1	被験者 1 名の関節角度と異常スコアの時間変化の一例	63
4.4.2	関節角度の最大値，最小値，実可動域の比較	64
4.4.3	異常スコアの平均および変動係数	65
4.4.4	各実験条件のしきい値を超えた異常スコアの数	66
4.4.5	ラグ L の採択率	67
4.5	考察	67
4.5.1	異常スコアと作業姿勢のばらつきの関係	67
4.5.2	ラグ L の最適なパラメータの選択	68
4.6	小括	69

第 5 章	時系列データを対象とした異常検知手法による作業動作評価： 特異スペクトル変換に基づく経時的な作業姿勢変化の検出	71
5.1	緒論	71
5.2	理論	72
5.2.1	特異スペクトル変換の概要	72
5.2.2	新しい異常スコアの計算方法の提案	73
5.3	実験方法	74
5.3.1	被験者	74
5.3.2	実験条件	74
5.3.3	測定項目と解析方法	74
5.4	結果	77
5.4.1	動作のばらつき	77
5.4.2	異常スコア	78
5.4.3	作業ペース	81
5.4.4	主観評価	81
5.5	考察	82
5.5.1	提案手法を用いた動作のばらつきの推定の有用性	82
5.5.2	今後の課題	83
5.6	小括	84
第 6 章	時系列データを対象とした異常検知手法を用いた作業動作評価： スパース構造学習による関節の協調関係の特徴の抽出に基づく 作業姿勢の経時変化の評価	85
6.1	緒論	85
6.2	理論	86
6.2.1	グラフィカル Lasso	86
6.2.2	グラフィカル Lasso に基づく相関異常度の計算	87
6.3	実験方法	88
6.3.1	被験者	88
6.3.2	実験条件	88
6.3.3	測定項目と解析方法	89
6.4	結果	90
6.4.1	グラフィカル Lasso による主要な関節間協調の抽出	90
6.4.2	異常スコアの経時変化	92
6.4.3	タスク A の肘関節屈曲角のそれぞれの異常スコアの傾向	94
6.4.4	タスク B の前腕回内角のそれぞれの異常スコアの傾向	94
6.5	考察	95

6.6	小括	96
第 7 章	結論	97
7.1	結論	97
7.2	今後の展望	100
参考文献	103
謝辞	115

第1章 緒論

1.1 研究背景

1.1.1 機械の自動化に伴う人間の作業の変化

IoT (Internet of Things) や Cyber-physical System などを含む Industry 4.0 の普及に伴い、生産現場の自動化やデータ化・コンピュータ化が進められている。特に Industry 4.0 が人間工学に与える影響の1つとして、手作業の自動化は頻りに言及されている[1]。Kadir et al.[1]によれば、多くの文献が反復作業は自動化されるが、同時に自動化には柔軟性がなく、自動化できるタスクは限られると述べている。実際に、人間の適用能力や学習能力の高さが要求される高品質の製品の生産場面やカスタマイズ製品の製造場面[2]や問題解決能力を必要とする複雑なタスク[3][4][5]において依然として手作業は重要である。また、自動化により減少する反復作業は主に負荷の大きいものに限定され、低負荷・高反復作業は依然として手作業が主流である[6]。したがって、作業者の作業姿勢や身体負担の評価に基づいた作業環境設計が重要である。しかし、昨今の作業現場のような低負荷・高反復作業の評価の場合、作業姿勢や身体負担の大きな変化が生じないため、作業内や作業間でわずかな姿勢・動作や身体負担の違いを検出および分析することが求められ、従来の人間工学評価手法では対応が困難な場面が多くみられる。したがって、わずかな動作の違いを検出し、身体負担や作業性を定量的に評価する手法の構築が望まれる。

人間では判断できないわずかな姿勢および動作の違いを判別し、身体負担評価を行うために、ここ数年の計算機技術の発展によって応用分野が拡大している機械学習、ディープラーニング、AI (artificial Intelligence, 人工知能) などの計算技術の応用が期待される。これまでも、人間工学分野のいくつかの研究で機械学習は用いられている。古くは、線形重回帰分析に代わる感情とデザインの関係の解析および感性評価の規則性を発見するためのツールとしての自己組織化ニューラルネットワーク (self-organizing neural network) の応用[7]や自動車シートの座り心地の検出における統計モデルと人工ニューラルネットワークの比較[8]など、統計モデルの発展としてしばしば使用されてきた。近年では、動的な人間の動作の検出[9]、ニューラルネットワークを用いた筋電図信号の特徴による NIOSH Lifting Equation の持ち上げ指数の推定[10]、ディープラーニング (deep learning) の1つである畳み込みニューラルネットワーク (convolutional neural networks) による RGB-D 画像からの関節角度推定[11]など、統計モデルの発展以外の用途にも利用されている。しかし、作業者の熟練度や身体特性などの様々な要因によって作業姿勢が多様に変化するため、正解となる作業姿勢の教師データを明確に定義することは困難である。したがって、人間では判断できないわずかな姿勢および動作の違いを判別するのに教師あり学習アルゴリズムを適用することは難しい。そのため、教師なし学習 (unsupervised learning) のような事前にラベルの定義を必要としない手法を適用する必要がある。異常検知手法は教師なし学習アルゴリズムであり、通常期待されるデータと異なる振る舞いを示すデータを検出する手法であることから、わずか

な姿勢および動作の違いを判別する問題に対する有効な手法の1つと考えられる。

1.1.2 様々な人間工学的作業評価手法

作業現場では、作業中に発生する不自然な姿勢などにより、作業者の筋骨格系に過度な負担が生じないように対策を取ることが要求される。そのためには、作業者の姿勢や外力などの条件から身体負担を見積もり、身体負担が許容範囲内か判定する必要がある[12]。代表的な評価手法として、作業者を目視で観察し、大まかに姿勢の評点を付ける観察法と呼ばれる手法やデジタル記録ツールを用いて記録された姿勢データに基づきコンピュータ上で作業姿勢を再現し、身体負担の推定等を行う生体力学解析が作業現場における身体負担推定のためにしばしば用いられる。

1.1.2.1 観察法 (observational method)

観察法の多くは評価シートなどを用いて作業姿勢、外力、動作速度、繰り返し回数などの評価項目を大まかに区分して記録するものであるため、特別な装置・器具などが不要で、生産現場への導入が比較的容易である[13]。しかし、評価区分が大まかなため、精緻な評価が困難である点や評価者による評価のばらつきが生じるため定量化が困難であるなどの問題点が存在する。表 1.1.1 は代表的な観察法とその概要を示している。

表 1.1.1 代表的な観察法とその概要

年	手法	概要
1977	OWAS (Ovako working posture analysing system)	ある時刻における作業姿勢を背部・上肢・下肢・重さの4項目でとらえ、これらをコード化した4桁の数字で記録し、4段階のAC (Action category) で評価する手法。
1979	AET (Arbeitswissenschaftliches erhebungsverfahren zur tätigkeitsanalyse [ergonomic job analysis procedure])	チェックリストを用いて作業負担を評価する手法。様々な職業分野における参考となるデータや経験に基づいてチェックリストが作成されている。ただし、筋骨格系を評価する対象となるのは216項目中17項目とごくわずかである。
1979	Posture targeting	作業姿勢のみを対象としてコード化して評価する手法。静的な姿勢の評価にのみ適している。ただし、持続時間と頻度は考慮できず、多くの身体部位の同時観察は困難である。
1982	ERGAN (ergonomic analysis)	Borgの主観尺度に基づいた作業姿勢の記録と負担評価を実施する手法。コンピュータによる記録と例示的な出力が可能であるが、計算に時間がかかることやソフトウェアの可用性が不明という課題もある。
1987	トヨタ式機能評価法	トヨタ自動車株式会社の安全衛生管理部が開発した調査票を基に作業負担を評価する手法。作業姿勢と重量のスコアをそれぞれ評価し、それらを総合したスコアにより負担の強度を算出する。低い位置での作業姿勢の観察が充実している。
1989	EWA (ergonomic workplace analysis)	反復作業のための身体負担および作業姿勢に関する質問を用いて上肢の運動を評価する手法。
1990	HSE (health and safety executive) upper-limb risk assessment method	リスク要因に関する質問にYesかNoで回答する手法。多く繰り返されるタスクや多様性のないタスクに対して適用できる。使いやすく、簡単な質問で構成されており、考えられる解決策に関するアドバイスの提供も可能。ただし、リスク因子の相互作用は考慮されず、主観評価のため、観察項目の定義が不明確である点やリスクを定量化するための測定基準が存在しないなどの課題がある。
1991	Stetson's checklist	チェックリストを用いて作業負担を評価する手法。ほとんどの項目が研究文献に基づいて選択されている。ただし、リスク因子の相互作用の考慮や、主観評価に基づくため観察項目の定義が明確でない点やリスクを定量化するための測定基準などが無いことが課題として挙げられる。
1992	TRAC (task recording and analysis on computer)	OWASと同様の手続きを用いて作業負担を評価する手法であるが、専用の計算機やソフトウェアを併用して、解析や評価を迅速に行うことを重視している。

表 1.1.1 代表的な観察法とその概要（続き）

年	手法	概要
1992	Keyserling's Checklist	作業姿勢で健康リスクがあるとされる全身・下肢・体幹・頸部の姿勢を 15 個選別して作成されたチェックリスト。リスクのある作業を見落とさないことを優先して作成しているため、リスクのない作業を誤ってリスクありと判断する可能性がある。
1993	NIOSH revised lifting equation	作業姿勢や繰り返し頻度などから取り扱う荷物重量の推奨限界を求め、実際に作業中に取り扱う荷物重量との比に基づき腰痛の発症リスクを評価する手法。
1993	RULA (rapid upper limb assessment)	上肢負担評価のための手法。上肢の評価は、上腕、前腕、手首の角度に基づくスコアから、上肢の総合スコアを求める。捻り、反復、力の発揮、および荷重の有無などがある場合にスコアを加算する。上肢の他に頭部、体幹部、下肢の姿勢についても同様にスコアを算出し、全ての部位について総合したスコアを求める。総合スコアを 4 段階の AL (Action level) を用いて評価する。
1993	Keyserling's cumulative trauma checklist	上肢の蓄積外傷性障害の発症に関連する人間工学的リスク因子の有無を判断するためのチェックリスト。素早く、簡単に使用できるが、評価システムが定性的であることや、リスク要因の相互作用は考慮されていないという課題がある。
1994	PEO (portable ergonomic observation)	作業姿勢をコード化して記録する手法。開始時と終了時の姿勢を記録することで、姿勢の持続時間の記録が可能になった。詳細な計算に時間がかかることや、作業ペースが速い場合、いくつかのばく露項目の評価ができないという課題がある。
1995	HARBO (Hands relative to the body)	PEO と同様に作業姿勢をコード化して記録する手法。習得しやすく、使いやすいという特徴がある。
1995	PLIBEL (Plan för identifiering av belastningsfaktorer [a method assigned for the identification profile of items knowledge of work of ergonomics hazards])	作業負担評価のための、Yes/No で回答するチェックリスト。比較的シンプルな評価方法であるが、リスクの定量化が困難である点や、Yes/No での回答に限界があるなどの課題がある。
1995	Strain Index	上肢遠位端の障害の発症に関連する作業のリスクレベルを比較的単純に評価できる手法。主に手（上肢）の反復タスクの評価が推奨されており、静的なタスクや不自然な姿勢のタスクには不向きである。

表 1.1.1 代表的な観察法とその概要（続き）

年	手法	概要
1996	PATH (posture, activity, tools and handling)	OWAS と同様の手続きを用いて作業負担を評価する手法であるが、専用の計算機やソフトウェアを併用して、解析や評価を迅速に行うことを重視している。現場で使用しやすいように徹底的に開発されているが、習得までに十分な訓練が必要である。
1997	ACGIH HAL (American Conference of Governmental Industrial Hygienists hand activity level)	VAS (visual analog scale) による手の活動と必要な力を評価する手法。素早く、簡単に使用でき、評価では個々の能力が考慮されるという利点がある。ただし、考慮できる要因の数が限られているという課題点がある。
1997	Arbouw	重量物の持ち上げ/持ち下げ動作を対象とした評価法で、3段階のリスク評価用の表を用いて評価される。持ち上げ、運搬、押し引き作業が評価の対象である。ただし、解析に時間がかかる一方で詳細な解析が困難である。
1998	OCRA (occupational repetitive actions)	反復作業に対応した手法。回復期間の考慮、複雑な仕事で繰り返されるすべてのタスクを考慮できるという利点のほか、チェックリストが簡単ですぐ使用できるという利点がある。ただし、使用に時間がかかることや、訓練を受けた観察者が必要であるという課題がある。
1999	QEC (quick exposure check)	チェックリストを用いた評価法で、使いやすく、幅広いタスクに適用でき、リスク要因の相互作用を考慮できる。ただし、複雑なタスクには適用が困難である。
2000	REBA (rapid entire body assessment)	RULA の後継に当たる作業負担の総合評価法。RULA と違い、下肢の肢位による評価項目や、持ちやすさに関するスコア (Coupling score) が追加されている。また、総合的な評価点の算出手順も変更されている。
2000	Washington State ergonomic checklist: (Washington State's caution zone, Washington State hazard zone, Washington State lifting calculator)	チェックリストを用いた作業負担評価法。標準的な作業に関する質問へ Yes/No での回答、リスク要因が組み合わせられた質問に対する Yes/No での回答、複数のスコアから持ち上げ限界の計算が行われる。簡潔、迅速に持続時間と頻度を伴うほとんどのリスク要因を考慮できる。ただし、リスクのスクリーニングに使用が限定される。
2000	VIDAR (Video- och datorbaserad arbetsanalys [a video- and computer-based method for ergonomic assessments])	作業姿勢の記録と身体負担の評価を実施する手法だが、作業負担の評価に主観評価を用いている。使いやすく、作業者が評価に参加することを推奨している点の特徴である。

表 1.1.1 代表的な観察法とその概要（続き）

年	手法	概要
2001	New Zealand code for material handling	重量物の持ち上げ/持ち下げ動作を対象とした手法. 荷物のサイズや形状, 床の状態など多くの重要な要素を考慮している.
2001	LUBA (postural loading on the upper-body assessment)	身体各部の不快感を数量化する手法で, 測定された関節角度を基に上半身の不快感を決定する. 上体や上肢の関節角度と不快感の関係を数値化したデータが評価基準のベースとなっており, 中立位から遠ざかるにつれて不快感を示すスコアが増加する. ただし, 負荷の大きさや, 持続時間, 繰り返しが考慮されていない.
2002	Chung's postural workload evaluation	LUBA を拡張した手法で, 四肢の肢位と体幹の姿勢を基に身体各部の不快感を算出する. LUBA と異なり, 下肢の評価項目が追加されており, 膝関節屈曲角あるいは該当する脚部の姿勢を選択して評価する.
2002	MAC (manual handling assessment charts)	重量物の持ち上げ/持ち下げ, 運搬, チームリフティングによる負担強度を評価する手法. 評価チャートに従って, 複数の項目を3段階あるいは4段階にて評価し, それぞれの得点を集計するため, クイックレビューがしやすいという特徴がある.
2004	ManTRA (manual tasks risk assessment)	クイーンズランド州の手作業諮問基準に記載されている規則に則り作業リスクの総合スコアを算出する手法. 素早く, 単純に使用でき, マニュアルマテリアルハンドリングタスクの一般的なリスク要因を考慮できる手法である. ただし, 主観評価ベースのため, 明確な基準が定義されていないという課題がある.
2004	ACGIH lifting TLV (threshold limit value)	繰り返しのある持ち上げ動作による腰背部と肩腕障害発生のリスク評価を行う手法. 繰り返し回数と取り扱い対象の作業点を参照して取り扱い対象の重量の許容限界値を決定する. ただし, 両手での単一の持ち上げタスクに使用が限定される.
2005	ULRA (upper limb risk assessment)	反復作業における上半身と四肢の負担および筋骨格系障害発症リスクを評価するための手法.
2006	AAWS (automotive assembly worksheet)	Schaub et al.が作成した作業評価表を基に作業負担を評価する手法で, 姿勢, 作業動作, 運搬の3つの項目の合計より作業負担の強度を判定する. 姿勢の選択肢が多いことが特徴で, 立位, 座位, 膝立ち, 仰臥位などの人の基本姿勢をほぼ網羅している. また, 運搬に関しては, 重量や作業台車の種類の他に, 作業台車の操作条件による影響も評価できる.

表 1.1.1 代表的な観察法とその概要（続き）

年	手法	概要
2008	BackEst (back-exposure sampling tool)	姿勢、マテリアルハンドリング、および全身の姿勢の振動に関連する背部のケガのリスク要因に対する物理的ばく露を評価する手法。観察者を増やすことでほとんどの評価指標の評価の信頼性が向上するが、一部の評価項目の評価者間の評価の信頼性は不明のままであった。
2008	ART (assessment of repetitive tasks)	反復作業における上肢の作業のばく露スコアを定性的アプローチに基づく数値スコアリングシステムによって算出する手法。
2012	HARM (hand arm risk-assessment method)	負荷の軽い手作業に対する腕、頸部、または肩の痛みを発症するリスク評価を行う手法。
2012	SWEA (model for assessment of repetitive work by the Swedish work environment authority)	筋骨格系障害予防のための作業環境設計に関するガイドライン。
2012	EAWS (European assembly worksheet)	AAWS が欧州規格の ISO11226, ISO11228, EN1005-4 など姿勢および動作にかかわる人間工学の規格のすべてを包含する仕様となった評価法。すべての国際規格・欧州規格を満たすように作り込んでいるため、記録項目は非常に多くなっている。
2013	NERPA (new ergonomic posture assessment)	3D CAD ツールとデジタルヒューマンモデルを使用して開発された、製品プロセス設計に適した手法。本法のスコアリングシステムは RULA を改変したものである。
2013	ERIN (evaluación del riesgo individual [individual risk assessment])	発展途上国の熟練度が低い評価者でも作業評価を行うことができるように IEA (International Ergonomics Association) と WHO (World Health Organization) 主導で開発された手法。部位別の姿勢のスコアに動作頻度のスコアを加えるという特徴がある。
2014	SES (Scania ergonomic standard)	観察法による作業姿勢評価に加えて、NIOSH lifting equation の評価を組み合わせ、総合的に作業負担評価を行う手法。
2017	ALLA (agricultural lower limb assessment)	韓国で開発された様々な農業タスクにおける下肢の作業姿勢の評価を行う人間工学チェックリスト。
2017	PERA (postural ergonomic risk assessment)	ISO11226 および EN1005-4 に基づいた作業サイクルにおける作業姿勢の危険因子を評価する手法。比較的シンプルにも関わらず EAWS の評価とほぼ同じ評価結果を記録しているため、評価結果の精度が良いことが特徴である。ただし、外力や反復的な動作によるリスクレベルのより詳細な分析と定義の追加の検証が必要である。

代表的な観察法の1つがOWASである。OWASはKarhu et al.により開発された手法[14]で、ある時点の作業姿勢を背部・上肢・下肢・重さの4項目でとらえ、これをコード化した4桁の数字（姿勢コード）で記録する。各項目のコードは以下の表1.1.2のように定義される。評価者は一定時間おきにその瞬間の作業者の姿勢を読み取り、姿勢コードで用紙に記録する。姿勢コードは4段階のAC（Action Category）で評価され、AC1は「筋骨格系の負担に問題はなく改善は不要」、AC4は「筋骨格系への負担が非常に高く直ちに改善が必要」と判定される。OWAS法は特別な測定機器を使用せずに作業の観察のみで実施できる簡便性と記録結果から直ちに改善すべきポイントを指摘できる迅速性を持つ。姿勢コードの分類が大まかなため、作業姿勢による筋骨格系負担の大まかな定量的評価へ向くが、詳細な記録・評価へは不向きという問題点を持つ。現在においても、コンピュータ支援OWASと呼ばれる様々なOWASベースのソフトウェアが開発されている。Kant et al. [15]は最初のソフトウェアを開発し、その後、COWAS（Computerised OWAS）[16]などの様々なコンピュータ支援型OWASが開発されている。しかしこれらの手法は、姿勢のコーディング作業を完全に自動化できないため、機械学習や画像処理を用いてコーディング作業を自動化してOWASで評価する手法[17][18]が開発されている。また、伐採作業の身体負担評価のために用いられREBA [19]と評価結果を比較される[20]など、依然としてOWASによる評価は産業現場での身体負担評価のために活用されている。

表 1.1.2 OWAS の評価項目

1. 背部	1) まっすぐ 2) 前または後ろに曲げる 3) ひねるまたは横に曲げる 4) ひねりかつ横に曲げる、または斜め前に曲げる
2. 上肢	1) 両腕とも肩より下 2) 片腕が肩の高さあるいはそれより上 3) 両腕が肩の高さあるいはそれより上
3. 下肢	1) すわる 2) 両脚をまっすぐにして立つ 3) 重心をかけている片脚をまっすぐにして立つ 4) 両膝を曲げて立つか中腰 5) 重心をかけている片脚を曲げて立つか中腰 6) 片脚または両方の膝を床につける 7) 歩くまたは移動する
4. 重さまたは力	1) 10 kg 以下 ($w \leq 10 \text{ kg}$) 2) 10~20 kg ($10 < w \leq 20 \text{ kg}$) 3) 20 kg より大 ($20 \text{ kg} < w$)

RULA も代表的な観察法の1つである。RULA は McAtamney and Corlett[21]によって提案された上肢作業負担評価のための観察法である。RULA の概要を以下の図 1.1.1 に示す。当時の産業現場における作業内容が全身作業から上肢中心の作業へと変化したため、OWAS よりも上肢を詳細に評価可能な手法として提案された。上肢の評価は、上腕、前腕、手首について角度に対応したスコアを付けた後、上肢の総合スコアを求める。その際、捻りや反復がある場合や上肢で力を発揮したり、荷重を支えている場合にスコアを加算する。上肢のほかには頭部と体幹部、下肢の姿勢についても同様に角度に基づいてスコアを算出し、全ての部位について統合したスコアから総合評価を行う。総合評価は4段階のAL (Action Level)で行われ、AL1は「長時間続けたり繰り返さない限り許容できる」、AL4は「直ちに調査と変更が必要」として判定される。本法には手首の角度など瞬間的な視認が困難な項目があるが、これは作業全体を見て評価する利用法を想定しているためである。力や荷重の大きさも静的な荷重を対象とし、2~10 kg がひとまとまりにされるなど区分も大まかである。ただし、反復性や衝撃性の力発揮に対してはスコアが加算される。現在でも RULA は、その即時性ゆえに、Kinect v2 (Microsoft) を用いたリアルタイムでの姿勢評価[22]やディープラーニングを用いたビデオカメラ映像からの姿勢評価[23]などに用いられている。

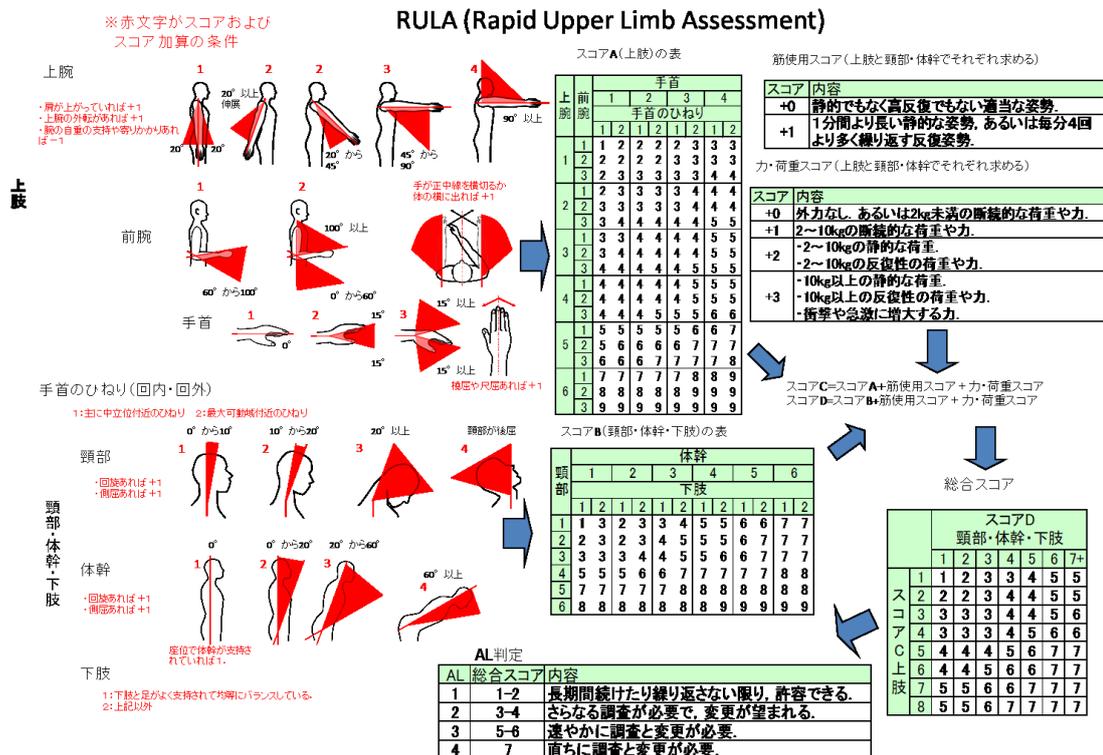


図 1.1.1 RULA による評価の概要

NIOSH Lifting equation は 1981 年に米国労働安全衛生研究所[24]によって提案され、1993 年に改訂版[25]が提案されている。作業姿勢や繰り返し頻度などから取り扱う荷物重量の推奨限界を求め、実際に作業中に取り扱う荷物重量との比に基づき腰痛の発症リスクを評価する手法である。より精緻に荷物取り扱い時の重量を評価できるように、荷物の取り扱い位置や重量のほかに、作業頻度や動作速度に関しても考慮されている。

生産現場ではひとまとまりのタスクの組み合わせから一連のタスクが成り立つことが多いが、各タスクが同じ作業の繰り返しになっている場合、作業者は同じ姿勢や動作を繰り返し取ることになる。そのため、作業負担評価値としては各タスクでの身体負担要因（荷物重量、繰り返し回数、運搬時の姿勢、延べ作業時間など）を組み合わせることでタスクの負担度が定量化でき、それを積み上げて一日の作業負担の定量化を可能にした作業評価法の 1 つが本法である。

NIOSH Lifting equation では *RWL* (Recommended Weight Limit, 推奨重量限界) と呼ばれる値を求める。*RWL* は以下の式で計算される。

$$RWL = LC \times HM \times VM \times DM \times AM \times FM \times CM. \quad (1.1)$$

ここで、*LC* は負荷定数、*HM* は水平係数、*VM* は垂直係数、*DM* は距離係数、*AM* はひねり係数、*FM* は頻度係数、*CM* は結合係数を示す。*RWL* が求められたら、次に以下の式で *LI* (Lifting Index, 持ち上げ指数) を求める。

$$LI = L/RWL. \quad (1.2)$$

ここで、*L* は実際の作業で取り扱う荷物の重量である。*LI* は式が示す通り、実際の作業の負荷が推奨限界である *RWL* の何倍になるかを示す値である。取り扱う荷物の重量が与えられた作業条件での荷物取り扱い作業の限界重量である *RWL* を超えている、すなわち *LI* が 1 より大きくなることは、腰痛の発症リスクが高いことを示す。作業現場では、*LI* が 1.0 以下になる作業設計が求められる。また、2007 年に連続した複数のタスク向けに *LI* を拡張した *SLI* (Sequential Lifting Index) [26]、2009 年により変化の多い持ち上げ評価用の *VLI* (Variable Lifting Index) [27]、2016 年に複数作業の生体力学的負荷を統合するための *CULI* (Cumulative Lifting Index) [28] などの指標が提案されている。

他にも 1998 年に Occhipinti によって提案された OCRA は繰り返し作業による負荷を評価する観察法である[29]。この手法は、作業現場で見られる作業内容が軽負荷・高反復作業へ変化したことに対応している。また 2018 年に、OCRA と EAWS[30] と併用した上肢リスク評価手順が提案されている[31]。EAWS は、Key Indicator Method という名称の人間工学評価手法に基づいている。この Key Indicator Method を自動車組立作業用に拡張した AAWS という

う手法が 2006 年に提案された。その後、欧州規格の ISO-11226, ISO-11228, EN1005-4 などの姿勢や動作に関わる人間工学の規格の全てを包含した姿勢評価法として EAWS が提案された。また、PERA も短い周期の組立タスクを評価するための観察法として 2017 年に提案された[32]。このように現在は、反復作業に対応した観察法もいくつか開発されているが、精緻な評価が困難である点や評価者による評価のばらつきにより定量的評価が困難であるという課題は依然として残っている。

1.1.2.2 生体力学解析 (Biomechanical analysis)

観察法と平行して、デジタル記録ツールを用いて姿勢を記録する手法がしばしば使われてきた。これらの手法は写真やビデオ、モーションキャプチャシステムなどを用いて作業姿勢を記録した後、コンピュータ上に作業姿勢を再現し、定量的に生体力学評価を行う。通常、作業者の身体を体節の組み合わせで表現したリンクモデルがしばしば用いられ、各関節まわりに生じる力学的負荷を 2 次元、あるいは 3 次元で計算し、身体負担を推定する。これらの手法は、一度作業内容を記録すれば観察者による評価に差が生じず、物理的評価尺度に基づいて結果を比較できることから作業現場へ導入が進められている。しかし、姿勢記録装置の設置や利用手順の習得に手間がかかることや、作業者と作業設備の干渉、カメラの死角などが生じると作業姿勢の欠損が発生するなどの問題点が存在する。そのため、作業者に直接センサを取り付ける、または反射マーカのような記録用のオブジェクトを取り付けて直接作業姿勢を計測する手法が提案されてきた。

観察法よりも細かく定量的に身体負担評価を行うために、生体力学モデル[33]を用いた計算に関する研究が進められている。この手法では、人間の身体に関する様々なデータを用いて身体特性をモデル化し、関節モーメントなどの物理的負荷を指標として身体負担を評価する。

モデル構築のためにいくつかのデータが必要となる。まず、人のセグメント長、セグメント質量、重心位置、回転中心などの人体計測学的データ[34]が必要である。これらのデータは身体の解剖学的研究などから測定され、セグメント長は身長に対する比、セグメント質量は体重に対する比として表されている。このデータはいくつかの研究グループによって提案され、それらを総合的に考慮した値が Chaffin et al.[35]によって提案されている。

次に、身体セグメントの並進・回転の変位、速度、加速度などの運動学的データが必要である。身体のランドマークの変位を観察し、セグメントの位置と傾きを求め、関節角度を算出する。基本的には、2次元の1つの平面内で観察を行うが、身体のひねりを伴う場合などは3次元的分析が必要になり、3つの平面にまたがった解析が必要となる。姿勢データは、姿勢・動作の自動生成アルゴリズム[36]や人体動作データベース[37][38]の発展によって、様々な作業場面に対応した姿勢を比較的高精度で再現することが可能になりつつある。

最後に、身体に生じる力と身体運動の関係を記述する運動力学的データである。運動のメカニズムを明らかにするために、筋による力のモーメント、筋のパワー、エネルギーの変化な

どが計算される。力には内力と外力が存在し、内力は筋活動、靭帯、筋や関節の摩擦などから生じる。外力は、外的な負荷、他の物体、空気抵抗などの受動的な力発生源から生じる。

1.1.2.3 デジタルヒューマンモデル (Digital Human Modeling)

生体力学解析を行うために、デジタルヒューマンモデル技術がしばしば用いられる。デジタルヒューマンモデルは人間の機能をコンピュータ上に再現する技術である。1980年代の計算機の能力の向上によって、身体機能のモデリング技術も同様に発展したことに伴い、生体力学解析に基づく正確な計算とモデリングが可能になり、デジタルヒューマン技術の開発に関する研究が多く行われてきた[39]。

デジタルヒューマンモデルとシミュレーションの中心となるのは、人体の生体力学的表現と姿勢や動きを生成する計算アルゴリズムである[40]。デジタルヒューマンモデルは2つの特性を備える必要がある。1つは、生体力学的構造がほとんどの人体の可動域をリアルに表現するのに十分なレベルの洗練度(例えば、自由度の数など)とモデルで再現された姿勢または動きを備える必要がある。第二に、計算アルゴリズムは時間効率がよく、リアルタイムまたはほぼリアルタイムで人間の姿勢や動作を表現することが可能である必要がある。デジタルヒューマンモデルでのシミュレーション時には、生成された姿勢または運動に小さな誤差があると、関節の負荷と筋力の推定に重大な誤差が生じることが報告されている[41][42]。計算効率は、人間のモデリングをデジタル化するという包括的な目標であるだけでなく、コンピュータ支援設計または人間工学アプリケーションによって実際に高められる基本的なソフトウェアのユーザビリティに関する要件でもある。

人間の動作の予測モデルの解説を行う前に、4つの基本的な計算手順と人間の動きのモデリングで発生する2つ主要な計算上の課題について述べる必要がある。4つの基本的な計算手順には、順運動学(直接運動学)、逆運動学、順動力学(直接動力学)、逆動力学が含まれる。順運動学は、既知の関節角度またはセグメント角度から関節および指先などの末端部位の座標を計算する手法である。逆運動学は、既知の関節座標または末端部位の座標から関節角度またはセグメント角度を決定する。順動力学は、筋の活性化または神経の興奮から始まり、体の動きを導き出す手順を指す。この手順は人間の動作の生成におけるイベントの真の一連の流れを示している。対照的に逆動力学は、既知または測定された身体の動きから関節の反力とモーメントを推定する。人間の動作の生体力学モデルでは、通常関節角度(自由度)の数は、末端位置の自由度よりも大きく、筋の数は動きを指定する自由度よりも大きくなる。したがって、2種類の冗長性が発生する可能性がある。1つは逆運動学における運動学的冗長性、もう1つは順動力学または逆動力学によって筋力を決定する場合の筋の冗長性である。実際に冗長性は、人間の動きのモデリングにおいて非常に根本的な問題、つまりBernsteinの問題を引き起こす[43]。冗長性を解決するためにしばしば使用される手段は最適化である。最適化では、パフォーマンス基準またはコスト関数としての様々な目的関数が定式化され、関節の動きまたは筋力を決定する際の最適な戦略を数学的に表現する。定式化された最適

化問題の性質はモデリングに関連する計算の複雑さに大きく影響する。

代表的な人間の動作のシミュレーションまたは予測モデルは 4 種類に分類される[40].

1) **筋組織のない静的モデル**: 静的最適化と逆運動学を使用して、離散的な姿勢決定問題を解く。 Joint Army-Navy Aircraft Instrument Research プロジェクトでコックピット設計用にボーイング社が開発した最も初期の 3 次元の静的モデルは、体幹部、首、上肢を表す大規模なリンクモデルで構成されていた。このモデルの最適化ルーチンは中立位からの姿勢偏差の総和を目的関数とし、それを最小化する。手の軌道の条件が与えられると、モデルは動作を計算するため、個別に最適化された一連の静的姿勢を生成できる。他にも関節負荷、不快感、エネルギー消費など目的関数が異なる同様のアプローチがいくつか提案されている。コンピュータアニメーション用の最適化ベースの人間の姿勢および位置決めアルゴリズムのいくつかもこのモデルに属する。動作シミュレーションに一連のまたは準静的な方法で静的モデルを使用する場合、いくつかの制限が存在する。まず計算量が非常に多くなるという問題点が挙げられる。次に、スムーズな速度や加速度の特性など、実際の人間の動きが持ついくつかの重要な特性が静的モデルでは考慮されていない場合がある。

2) **筋組織を備えた静的モデル**: このモデルは主に筋力と関節負荷を推定する目的で構築され、静的な最適化と逆運動学を動作中の静的姿勢または一連の個別の姿勢に適用する。このモデルの最適化ルーチンは、通常、筋肉のストレスを定量化する目的関数を最小化して、筋肉の冗長性の問題を効率的に解決する。同じモデル構造を使用することで各時間ステップにおける姿勢変化が特定の筋群のストレスまたは力を最小にするかを決定し、次に運動の一連または準静的シミュレーションを生成することが可能になる。ただし、このようなモデリングは、計算負荷が大きく、長さ-張力や速度-張力関係などの筋の生理機能を正確に表現することが困難であることが、より現実的なモデリングを実現する上での障害となっている。

3) **筋組織を備えた動的モデル**: 筋組織を備えた静的モデルは、シミュレートされた人間の動作を表現するために、神経筋骨格の順運動学と動的最適化を組み込んだ動的モデルへと発展した。主に、歩行や上肢動作をシミュレーションするために開発され、通常、筋の経路、筋腱の動作、興奮収縮連関などの筋組織の精巧な表現が特徴である。これらの動的モデルは物理的により妥当な運動を生成できるように思われるが、2005 年に報告された Zhang and Chaffin の研究[40]の段階では、あまりの計算量の膨大さに、妥当な時間での運動シミュレーションを行うことは困難であった。

4) **筋組織のない動的モデル**: 特に神経筋制御または筋骨格ダイナミクスへの定量的評価を行うことが主要な問題でない場合、計算の扱いやすさと効率を高めるために筋組織を除外するこのモデルは、高いレベルでの動的または運動学的パラメータの推定値を利用して順運動学または順運動学の手順を迅速に遂行するための 3 つの異なるアプローチを用いている。1 つは、コンピュータアニメーションの分野でしばしば用いられる手法で、ヒューリス

ティックまたは関節トルクの推定に基づき順運動学を単純化し、筋の冗長性の問題を効率的に回避するものである。2番目のアプローチは、統計的手法またはカーブフィッティング手法を使用して、測定された身体セグメントまたは関節角度を直接モデル化することを提案している。最適化ベースの微分逆運動学アプローチと呼ばれる3番目のアプローチは、末端部位の位置変化をマッピングするヤコビ行列のパラメータ化された疑似逆行列を通じて速度領域の運動学的冗長性を効率的に解くアプローチである。

Zhang and Chaffin[40]の研究によれば、人間の動作モデリングの研究には大きく2つの課題が存在することが示唆されている。最初の課題は、人間の動作モデル生成において、やや相反する2つの目標に対処することである。1つは、人間の筋骨格系の数学的表現における物理的な妥当性の向上である。ここで述べる物理的な妥当性は、コンピュータによって生成される動作の自然さを指すのではなく、その後の生体力学的または人間工学的分析の妥当性を指す。もう1つはシステムの複雑な動作のリアルタイムシミュレーションに向けて、計算の扱いやすさと速度の向上である。より精度の高いシミュレーションでは、モデリングに関係する変数の数が増え、リアルタイムでのシミュレーションは困難になるため、生体力学的な精緻さと計算効率の間には固有のトレードオフが存在する。2番目の課題は、より高精度の作業姿勢および動作データの取得に関連するとZhang and Chaffin[40]の研究で述べられているが、近年ではモーションキャプチャ関連技術の発展もあり、より高精度かつ膨大な量の作業姿勢および動作データの取得が可能になっている。

1.1.2.4 直接測定する手法

被験者にセンサを直接取り付け付けて作業中のばく露因子を測定する手法も数多く開発されてきた。モーションキャプチャシステムは物体や人間の動きをデジタルで追跡および記録する手法である。動作を計測するために様々な手法が開発されている。例えば、光学式または磁気式のモーションキャプチャシステムや、慣性センサや関節構造の相対的な動きを追跡するポテンシオメータに基づくモーションキャプチャシステムなどが存在する。

光学式モーションキャプチャシステムは、赤外線カメラを使用して作業者の身体ランドマークに貼付した反射マーカの位置を三角測量することにより各反射マーカの3次元位置を推定する。光学式モーションキャプチャの最大の利点は測定精度が高いことである。ただし、被験者にマーカを貼付する必要があることや、カメラを設置する必要があること、カメラに障害物が入ることによって測定精度が低下することなど、実作業評価へ応用するためにはいくつかの課題が存在する。

慣性センサに基づくモーションキャプチャは光学式モーションキャプチャに次いだ精度で姿勢を測定することが可能で、光学式モーションキャプチャよりも安価である。ただし、測定の際にはセンサのドリフトなどによる測定誤差が発生することや、無線センサの

場合はセンサのバッテリーの寿命の問題、有線センサの場合は被験者を拘束して作業姿勢に変化が生じるなどの課題点がある。

また、身体負担に関する評価指標を直接測定する方法として力の計測や筋電図による筋発揮の計測が挙げられる。筋電図は、筋収縮が起こる際に発生する活動電位の動きをとらえたものである。適切な条件下で、基本的な生理学とバイオメカニクスの原理および測定の原理に基づいて解釈することで有用な分析方法となりうる。しかし、適切な筋の選定が行われない場合、作業の条件の特徴が明らかになっていない場合、作業姿勢に関する然るべき測定が行われていない場合において筋電図から得られる情報の有用性は低下する。

これらの直接測定する方法は、様々なばく露要因に対する非常に正確なデータを大量に提供できるが、センサを被験者に直接取り付けることによる不快感の発生や作業動作の変化が生じる可能性がある。また、大量に測定されるデータの分析と解釈に時間がかかる点、計測機器に対する初期投資が高い点、測定者が精度の良いデータを得るために十分な訓練が必要である点なども課題として挙げられる。

近年ではマーカを用いることなく作業姿勢を計測する手法もいくつか開発されている。Kinect (Microsoft) を用いた手法はその代表例の1つで、Kinect を用いて RULA による姿勢評価を行った研究[22]や Kinect データを修正し、逆運動学に基づき、関節トルク比を推定した研究[44]、Kinect と Captiv (TEA group) による2つのマーカレスキャプチャの精度を比較した研究[45]などが存在する。また近年では、Cao et al.[46][47]により提案された OpenPose と呼ばれる手法により、ビデオ映像から人間の2次元の姿勢を畳み込みニューラルネットワークを用いて推定する。また、Nakano et al.[48]は OpenPose で推定された2次元姿勢から3次元姿勢を推定するアルゴリズムを提案した。人間工学分野での応用例として、OpenPose ベースの RULA による姿勢評価手法を開発した研究[49]、OpenPose がスクワット中の動作分析に有効か検討した研究[50]、OpenPose と物体検出に基づく反復的な組立タスクの活動認識を試みた研究[51]などが存在する。マーカレスのモーションキャプチャ技術の利点の1つは、作業者の拘束が存在しないことである。加えて、OpenPose のようなビデオカメラから作業姿勢を推定する手法は、従来は導入が困難であった作業場面への導入が可能になり、より広範囲の作業で人間工学評価が可能になる。さらに、複数人の同時人間工学評価への応用などにも期待される。しかし、作業姿勢の推定精度の問題や、関節角度の推定に基づく生体力学評価までの一連のシステムの構築など、実作業への応用にあたるいくつかの課題が存在する。

作業者の作業姿勢や身体負担に配慮した作業環境設計が作業の快適性向上のために重要であり、作業姿勢や動作の記録や解析と身体負担に関する多くの人間工学評価法が開発されてきた。特に、OpenPose などの機械学習ベースの姿勢計測手法は、従来の姿勢計測法よりも導入が容易であり、様々な作業条件の姿勢や動作を計測できる可能性がある。一方で、筋電図などの身体負担の直接測定法は、依然としてセンサ取り付けによる不快感の発生や

作業動作の変化が生じる可能性がある。したがって、今後は測定された作業姿勢や動作の解析に基づく作業の評価が要求される。さらに、近年の姿勢や動作の違いがわずかな低負荷・高反復作業の評価のためには、わずかな姿勢や動作の違いを検出して分析する手法が必要である。

1.1.3 機械学習・コンピュータビジョンの応用

1.1.3.1 機械学習の概要

機械学習の定義の1つは、「明示的にプログラムすることなく、学習する能力をコンピュータに与える手法」である。より簡潔に言うと、「データを与えることで、与えられた問題を解決する能力をコンピュータに自動で学習させる方法」と定義できる。類似した語句として、統計的機械学習という語句もしばしば使用される。こちらは、通常機械学習は真実が明らかにならなくても構わないが、真実が明らかになればより精度よく課題を解決できるという点を踏まえて、統計学に基づき真実を明らかにできるような形で機械学習を行うことを指す。

機械学習は教師あり学習と教師なし学習に大別される。教師あり学習はデータとそれに対する解答を組にした形で与えられる場合を指す。教師あり学習は問題に対する正解が分かっているため、効率的に学習することができる。一方、教師なし学習はデータのみが与えられ、解答が付与されていない場合を指す。解答が直接与えられていないため学習は難しくなるが、人間にとって未知だった新しい傾向や特徴を発見する可能性が高いため、それを主目的とするデータマイニングの分野でしばしば利用される。機械学習は他にも、半教師あり学習 (semi-supervised learning) や転移学習、強化学習などの学習方法の違いによる分類が存在する。

1.1.3.2 代表的な機械学習手法と人間工学評価への応用

ニューラルネットワーク (neural network, artificial neural network, 人工ニューラルネットワークとも呼ばれる) は代表的な機械学習の手法の1つである。1943年に生体システムにおける情報処理を数学的に表現しようと試みたものである形式ニューロン[52][53]が提案され、1958年に形式ニューロンを応用したパーセプトロンが提案されたが、教師ありの線形分離可能な問題しか解けないことから広く普及しなかった。しかし、1986年にバックプロパゲーションが提案されたことで非線形分離可能な問題も解けるようになり再び脚光を浴びた。近年では、計算処理能力の劇的な向上に伴いニューラルネットワークを大規模化した deep neural network[54]や、画像認識などでしばしば使用される畳み込みニューラルネットワーク (convolutional neural network) [55]、時系列データを扱うことが可能な再帰型ニューラルネットワーク (recurrent neural network) [56]、より脳の機能に近づけて活動電位 (スパイク) による処理を可能にしたスパイクニューラルネットワーク (spiking neural network) [57]など様々なモデルが提案されている。

人間工学分野では、古くは感性工学の評価への応用[7]、自動車シートの座り心地の評価モデルの構築[8]などにおいて、統計モデルに代わる手法として用いられていた。近年では、動的な人間の動作の検出[9]、表面筋電図の特徴から NIOSH Lifting equation の持ち上げ指数の推定[10]、呼吸信号と表面筋電図信号から呼吸器装着時の呼吸抵抗の認識[58]、自動車侵入における全身の動作の検出[59]など幅広い研究で使用されている。

サポートベクタマシン (support vector machine) [60]は近年、クラス分類、回帰、新規性検出などの分野でよく使用されるようになった。サポートベクタマシンの重要な特徴は、モデルパラメータがある凸最適化問題の解として求まるため、局所解があればそれが大域解にもなる点である。サポートベクタマシンはマージン (margin) という概念を用いて、汎化誤差が最も小さくなるような訓練データを正確に分離する解を求める。サポートベクタマシンは通常データを 2 つのクラスに分類するが、派生形として多クラスサポートベクタマシンや異常検知手法でも頻繁に使用される One-Class Support Vector Machine などが存在する。

人間工学分野では、車両進入時の主観的応答の予測のためにサポートベクタマシンを用いた研究[61]やサポートベクタマシンとファジィ推論システムを組み合わせた事故リスク評価システムの提案[62]、時間-周波数解析やサポートベクタマシンをはじめとする教師あり学習を用いた筋疲労状態の推定[63]に用いられている。

他の代表的な手法として、教師あり学習では、ロジスティック回帰、決定木、ランダムフォレスト、ナイーブベイズ、状態空間モデル、k 近傍法が知られており、教師なし学習では、ワード法に基づく階層型クラスタリング、k-means 法に基づく非階層型クラスタリング、自己組織化マップなどが知られている。

1.1.3.3 人間の動作分析

近年のモーションキャプチャ技術の発展によって、動作の利用用途を拡大させ、人間の動作分析に関する研究が活発になっている[64]。人間の動作分析 (human motion analysis) は、時間の経過とともに人間の動きを分析し、解釈することを指す[65][66]。人間の動作解析は主に、検出 (detection)、追跡 (tracking)、認識 (recognition)、行動理解 (behavior understanding) に大別される。認識と行動理解は人間の動作分析の中でもハイレベルな処理であり、認識したのちに行動理解が行われるため、これらの 2 つのステップをまとめて行動理解とする場合もある[64]。最も初期段階の処理として人間の検出があり、これはその後の解析のための前処理の段階として定義されている。次いで、人間の追跡が行われる。これは検出段階よりは高レベルの処理であるが、認識・行動理解と比較するとややレベルが劣る処理として位置づけられる。

人間の検出は、動作解析における初期の段階で、動画像から人に対応する領域をセグメント化することが主な目的である。追跡や行動理解などの後続なプロセスが検出の処理に大きく依存するため、人間の動作解析における重要な処理ともとれる。人間の検出は、動作のセグメント化とオブジェクトの分類に大別される。動作のセグメント化はある特定のシー

ンから動く物体に対応する領域を抽出することを目的とし、主な手法として背景除去[67]、統計的手法[68]、時系列差分[69]、オプティカルフローに基づく手法[70]などが存在する。物体の分類は人間以外の動く物体を動画像中から検出することを目的とし、形状に基づく分類[71]や動きに基づいた分類[72]などが含まれる。

人間の追跡は、姿勢推定や行動認識のためのデータを準備する手段としての役割を果たすため、人間の動作解析において重要である。人間の追跡は異なる基準に従ってモデルに基づく追跡、領域に基づく追跡、動的輪郭に基づく追跡、特徴に基づく追跡に分類される。モデルに基づく人間の追跡では、stick figures モデル[73]、2D contours モデル[74]、volumetric モデル[75]などのモデルが用いられる。領域に基づく追跡手法は、画像内の各移動オブジェクトに関連付けられた連結領域を特定し、その相互相関を使用して追跡する手法[76]などがある。動的な輪郭に基づく手法は、オブジェクトの輪郭を検出し、それを動的に更新し続ける手法などが代表例である。特徴に基づく動作の追跡は、オブジェクト全体をとらえる考え方とは異なり、オブジェクトの中の区別可能な点または線などに基づいて追跡する手法である。この手法には主に特徴抽出と特徴のマッチングが含まれる。点などの低レベルの特徴抽出は比較的容易だが、高次の特徴の抽出は困難であり、特徴抽出と追跡の精度の間にはトレードオフの関係が存在する。

行動理解は、人間の行動パターンを分析・認識し、行動と相互作用を理解することである。これは時間変化する特徴データの分類問題、いわゆる、未知の一連の動画像データを典型的な人間の行動を示すラベルデータと照合することである。人間の行動理解の基本的な問題は、訓練サンプルから一連の行動の学習、同様クラスの運動パターン内の空間および時間スケールでのわずかな変化に効率的に対処するための訓練とその照合、行動を効率よく解釈する手法の構築である。また、行動理解に関わる行動認識は、時間的に変化するデータマッチング問題と考えることができる。一般的には、Dynamic Time Warping[77]や隠れマルコフモデル (hidden Markov model) [78][79]、ニューラルネットワーク[80]などが使用される。Dynamic Time Warping は音声認識に主に使用されていた手法で、概念が単純かつ効果が大きいため人間の動作のパターンマッチングにも応用される。隠れマルコフモデルは、セグメント化されていない連続したデータを処理する Dynamic Time Warping よりも優れているため、人間の動作パターンの認識に広く応用されている。ニューラルネットワークは時間変化するデータを分析するアプローチで、現在ではより大きなデータセットを利用できるようになったため時間情報を加味できるニューラルネットワークがしばしば用いられるようになった。人間の活動認識は主にテンプレートマッチングと状態空間モデルに基づく手法で構成される。テンプレートマッチングは、事前に用意された動作のプロトタイプと比較することで活動を認識する。この手法は特徴抽出に基づいており、人間の行動を認識するための特徴を選択する必要がある。これまでに 2D メッシュからなるオプティカルフローに基づく特徴抽出[81]、時間的なテンプレートを用いた活動認識[82]、主成分分析を用いた特徴抽出に基づく活動認識[83]などが行われている。

1.1.3.4 動作の特徴抽出

人間の動作解析において特徴抽出は検出, 追跡, 行動理解の全ての領域において使用される技術である. 特徴抽出の目的は, モーションキャプチャ技術の発展により大量の人間の動作データを取得できる中で, 動きの変化のパターンを理解し, 効率よく解析することである. 代表的な手法として, 動作のセグメント化による特徴抽出[84], ウェーブレット変換を用いた波形変換に基づく特徴抽出[85], 主成分分析を用いた特徴抽出[86]などが報告されている. 主成分分析を用いた研究[86]では, 車両進入動作中の全身の動作データの中から特徴的な挙動を示す関節の抽出を試みている. また Li et al. [87]は, 高次元の構成空間からスパースモデリングの手法を用いて特徴点を抽出し低次元化したデータから関節の運動を再構築するアルゴリズムを提案している.

特徴抽出と非常に関連の強い動作解析手法として, 動作分割手法(または動作のセグメント化手法)が知られている. 人間の動作は多様な要素で構成されており, その各要素に多くの情報を持つことから, 人間工学的な研究において, 特定の動作に対する身体負担の寄与について関節や四肢ごとに評価を行う必要がある. その時, 動作をサブモーションとして表現する動作分割手法を用いることで, 一連の動作を区切って評価できる. この手法は反復的な動作の解析以外にも, 動的な動作, 運動の組み合わせ, そしてロボットの学習などの分野で用いられている[88][89]. 動作分割手法は近年では機械学習の手法がしばしば用いられ, 教師あり学習, 教師なし学習に基づく手法と主成分分析に基づく手法[90]などの学習を使用しない手法に大別される.

1.1.4 異常検知手法

異常検知手法は、予想される動作に適合しないデータのパターンを見つける問題を指す [91]。異常検知手法はサイバーセキュリティの侵入検知、安全上重要なシステムの障害検出、人の異常行動の検出など幅広い分野で活用されている。比較的単純な異常検知問題は、正常な動作を表す領域を定義し、この正常な領域に属さない観測値を異常として検出することで達成できる。しかし、以下に示すいくつかの要因はこの比較的単純な異常検知問題をしばしば困難にする。

- ・ 全ての正常な観測を含む正常な領域を定義することが困難である。さらに、正常な観測と異常な観測は多くの場合明確ではないため、境界付近の異常な観測は実際には正常である可能性もあり、逆もまた同様である。
- ・ 異常が悪意のある行動の結果である場合、悪意のある異常は観察結果を通常のように見せかけるよう自身を適用させることがしばしば見られ、正常な観測の定義がしばしば困難になる。
- ・ 多くの応用場面において正常な観測は変化する可能性があり、現在の正常な観測の概念は将来的に正常であるとは限らない。
- ・ 異常の正確な定義は応用分野によって異なる。そのため、ある分野で開発された手法を別の分野へ適用することは簡単ではない。
- ・ 異常検知手法で使用されるモデルの訓練または検証にラベル付きのデータを使用できるかどうかは重要な問題となる。
- ・ データには異常に似た傾向のあるノイズが含まれているため、区別してノイズを除去することが困難である。

上記の課題があるため、あらゆる異常を検出可能な異常検知問題の定式化は困難である。実際、既存の異常検知手法のほとんどは特定の問題に対する定式化を試みている。この定式化は入力データの性質、異常の種類、データラベルの有無、異常検知の出力などの要因により決定される。多くの場合、これらの要因は異常を検出する必要がある応用分野によって決定される。これまで多くの研究者は統計、機械学習、データマイニング、情報理論、スペクトル理論などの様々な分野の概念を採用し、特定の問題の定式化に適用してきた。

入力データの性質は異常検知手法の重要な性質である。入力は通常、収集されたデータである。各データは一連の属性（変数、特性、機能、フィールド、次元とも呼ばれる）を使用して記述され、バイナリ値、カテゴリ値、連続値など様々なタイプを持つ。各データは1つの属性のみ（単変量）または複数の属性（多変量）で構成される場合があり、多変量データの場合、全ての属性が同じこともあれば、または異なる属性が混合していることもある。属性の性質によって、どの異常検知手法を適用するかが決定される。入力データは、データ間の関係に基づいて分類することも可能である。一般にデータは相互に関連付けることがで

きる。代表的な例は連続データ、空間データ、グラフデータである。連続データでは、データは線形に並べられる（例：時系列データ、ゲノムシーケンスなど）。空間データでは、各データは隣接するインスタンスに関連付けられる（例：車両交通量データ、生態学的データなど）。空間データに時間的コンポーネントがある場合、時空間データと区別される。グラフデータでは、データはグラフ内の頂点として表され、エッジで他の頂点と接続される。

異常の種類も異常検知手法の決定において重要である。異常は主に 3 つのカテゴリに分類することができる。

1) Point Anomalies (点異常)

個々のデータインスタンスが残りのデータに関して異常であるとみなすことができる場合、そのインスタンスは点異常と呼ばれる。これは最も単純なタイプの異常であり、異常検出に関するほとんどの研究がこの点異常の検出を対象としている。

2) Contextual Anomalies (状況的異常)

データインスタンスが特定の状況で異常である場合、それは状況的異常（または条件付き異常）と呼ばれる。異常の条件はデータセットの構造によって引き起こされ、問題の定式化の一部として指定する必要がある。各データインスタンスは、次の 2 つの属性セットを使用して定義される。

① Contextual attributes (状況属性)

状況属性はそのインスタンスの状況（または近傍）を決定するために使用される。

例えば、現実空間のデータセットでは、場所の経度と緯度が状況属性となる。時系列データでは、時間はシーケンス全体でのインスタンスの位置を決定する状況属性である。

② Behavioral attributes (動作属性)

動作属性はインスタンスの非状況属性を定義する。例えば、全世界の平均降雨量を示す空間データセットでは、任意の場所での降雨量が動作属性である。

異常な挙動は特定の状況内の動作属性の値を使用して決定される。データインスタンスは特定の状況の状況異常である可能性があるが動作属性の観点から、同一のデータインスタンスは別の状況では正常とみなすことができる。この特性は、状況的異常を検出する手法において状況属性と動作属性を識別する上で重要である。状況的異常は時系列データや空間データで最も一般的に調査されている。

3) Collective Anomalies (集合的異常)

関連するデータインスタンスの集合がデータセット全体に対して異常である場合、集合的異常と呼ばれる。集合的異常の個々のデータインスタンスはそれ自体では異常ではない可能性がある。しかし、それらが集合として同時に出現することは異常である。

点異常はどのデータセットでも発生する可能性があるが、集合的異常はデータインスタンスが関連するデータセットでのみ発生する可能性があることに注意する必要がある。対照的に状況的異常の発生はデータ内の状況属性の有無に依存する。状況に関して分析された場合、点異常または集合的異常も状況的異常である可能性がある。したがって、点異常検出問題および集合的異常検出問題は、状況に関する情報を組み込むことにより状況的異常検出問題に変換できる。

データインスタンスに関連付けられたラベルは、そのインスタンスが異常か正常かを示す。正確かつあらゆる種類の行動の代表であるラベル付きデータを取得することは膨大なコストがかかる。ラベル付けは専門家が主導で行うことが多いため、ラベル付きの訓練データを取得することはかなりの労力が必要である。通常、考えられる全ての異常な挙動を反映した異常なデータインスタンスの訓練データセットを取得することは、正常な挙動のラベルを取得するよりも困難である。ラベルの有無によって異常検知手法は次の 3 つの手法に分類することができる。

1) 教師あり異常検知

教師あり異常検知は、正常と異常を区別したラベルを持つデータセットを利用可能であることが前提である。教師あり異常検知の典型的なアプローチは、正常クラスと異常クラスの予測モデルを構築することである。前提として、異常なデータインスタンスは正常データインスタンスと比較して非常に少なく、全ての異常データの挙動を反映するような訓練データセットを用意することはしばしば困難なため、教師あり異常検知を応用できる場面は限られる。

2) 弱教師あり異常検知

弱教師あり異常検知では、正常なデータインスタンスにラベルが付いたデータセットが利用可能であることを前提としている。弱教師あり異常検知は異常なデータインスタンスのラベルを必要としないため、教師あり異常検知よりも広く応用することができる。弱教師あり異常検知の典型的なアプローチは、正常データのクラスモデルを作成し、そのモデルを用いて異常データを識別する方法である。

3) 教師なし異常検知

教師なし異常検知は訓練データを必要としないため、最も広く適用可能である。教師なし異常検知は、異常な挙動を示すデータインスタンスが正常のデータインスタンスよりも非常に少ないことを前提としている。この仮定が当てはまらない場合、異常データの誤検出率が増加する。人間の作業姿勢や動作のように個人の身体特性・経験・動作方略によって値がばらつく指標は正常なデータと異常なデータの区別が困難である上に、正常となるデータの決定が困難であるため、教師なし異常検知の適用が妥当である。

異常検知の出力も異常検知手法選択の上で重要な要因の1つである。通常、異常検知手法によって生成される出力は次の2種類に大別される。

1) スコア

異常と判定されるインスタンスが異常とみなされる程度に応じてスコアを割り当てる方法である。解析においては、上位のスコアを示す異常を解析するか、しきい値を使用して異常を選択するかのどちらかの手法を選択する必要がある。

2) ラベル

各データインスタンスに正常または異常のラベルを割り当てる。データインスタンスにバイナリラベルを割り当てる手法では、解析者は直接割り当てることはできないが、各手法内のパラメータの選択を通じて間接的に制御することが可能である。

これらの各要因に基づいて異常検知手法は外れ値検知 (outlier detection), 変化点検知 (change detection, change-point detection), 異常部位検知 (discord discovery) の3つの検出問題に大別される。この中で、異常部位検知は外れ値と変化点が同時に発生しているような集会的異常検出問題と定義することができる。

1.1.4.1 外れ値検知

外れた観測値または外れ値は, Grubbs [92]によりデータセット内から著しく逸脱しているように見えるインスタンスであると定義され, Barnett and Lewis [93]はデータセットの残りの部分と一致していないように見える観測 (または部分観測) であると定義している。外れ値検知と類似した用語として, 新規性検出 (novelty detection) という呼び方もしばしば使用される[94]。外れ値検知は前述の異常のカテゴリでは, 点異常を検出する問題と捉えることができる。Hodges and Austin[95]によれば外れ値検知には3つの基本的な問題に対してアプローチすることが報告されている。

- 1) **データに関する事前知識なしに外れ値を特定する問題**：これは教師なしクラスタリングに類似した学習アプローチで, データを静的分布と定義し, 最も離れたポイントを特定し, それらを潜在的な外れ値としてフラグを立てる。この問題はエラーなどが通常のデータから離れているため外れ値として表示されることを前提としている。
- 2) **正常と異常の両方をモデル化する問題**：これは教師ありの分類問題と類似しており, 正常または異常として事前にタグ付けされたラベルデータが必要である。
- 3) **正常なデータのみをモデル化するか, ごくまれに異常もモデル化するような問題**: Hodges and Austin[94]はこの問題を新規性検出と定義している。この問題は半教師ありの認識または検出タスクに類似しており, 正常データのクラスがすでに教師データとして存在する状態でアルゴリズムが異常値の認識について学習する。この問題も事前に分類されたデータが必要だが, 正常データのみを学習する。正常データのクラスのみを学習することから, 動的なデータにも対応することが可能である。

代表的な外れ値検知の手法の 1 つとして、サポートベクタマシンを 1 クラス分類問題を扱うために拡張した **One-Class Support Vector Machine** が Schölkopf et al.[95]によって提案されている。通常のサポートベクタマシンは学習したデータを 2 つのクラスに分類する超平面を求める問題なのに対し、**One-Class Support Vector Machine** では、学習に使用される全てのデータインスタンスがクラス 1 であり、原点が唯一のクラス 2 と仮定する。この際、事前に定義された外れ値の上限を決めるハイパーパラメータに応じた数のデータが超平面を挟んで原点側に写像されるような超平面を求めることで、原点側に写像されたデータインスタンスを外れ値とみなす手法である。**One-Class Support Vector Machine** は、障害検出[96]、ビデオからの異常事象の検出[97]、メディア分類[98]、ネットワーク侵入検知[99]など多くの研究が行われ、産業場面へ幅広く応用されている。近年では、眼球運動データを **One-Class Support Vector Machine** へ適用し、運転中のメンタルワークロードの評価を行った研究[100]も報告されており、人間工学評価への応用も期待されている。

他にも距離に基づく外れ値検知として、マハラノビス距離に基づく外れ値検知、 $DB(f, D)$ 外れ値[101]、LOF (Local Outlier filter) [102]などが提案されている。マハラノビス距離に基づく外れ値検知は単純で、データ群の平均値を中心として、それからどの程度離れているかを分散共分散行列の逆行列を計量として測るものである。ただし、この手法は単峰の分布以外の複雑なパターンには、平均自体が外れ値の影響を受けるため対応できないという問題点がある。その問題点を解決するために、Knorr and Ng[101]により $DB(f, D)$ 外れ値が提案されたが、こちらも全体のデータから相対的に離れていなくても局所的な群からは離れているような局所的な外れ値は検知できないという問題があった。この問題点を解決するために、LOF が Breuning et al.[102]によって提案された。また、単純ベイズ法に基づく方法、近傍法に基づく方法、混合分布モデルによる逐次更新型異常検知、スパース構造学習に基づく異常検知、密度比推定による異常検知など多くの手法が存在する[103]。スパース構造学習に基づく異常検知や密度比推定による異常検知などは時系列データにおける変化点検知（または異常部位検知）にも応用される。多変量の時系列データに対する外れ値検知としては、主成分分析による手法などが知られている[104]。

1.1.4.2 変化点検知

変化点検知は時系列データの特性が変化したことによるデータに生じる急激な変化を見つける問題である[105]. 変化点検知と類似した手法として変化点推定が知られているが, 変化点推定は, 変化の発生を識別するのではなく, 時系列の既知の変化をモデル化して解釈しようとする点で異なる. 変化点検知の研究は, データマイニング, 統計, コンピュータサイエンスの分野で古くから研究されており, 現実の問題に広く応用されている[106]. 例えば, Aminikhanghahi and Cook[106]は, 以下のような実場面への応用例が存在すると述べている.

- 1) **病状の監視**: 患者の健康状態の継続的な監視や自動化されたリアルタイムでの監視を実施するために, 心拍数, 脳波, 心電図などの生理学的評価指標の変化点検知が行われている.
- 2) **気候変動の検出**: 気候変動の発生の可能性や大気中の温室効果ガスの増加などの要因により, 気候分析, 監視, および予測において変化点検知が応用されている.
- 3) **音声認識**: 音声認識のプロセスにおいても, 音声のセグメンテーションや, 無音・文・単語・ノイズの境界を認識するために変化点検知が応用されている.
- 4) **画像分析**: 収集された時間の経過に伴う画像データ, またはビデオデータからセキュリティ違反などの突発的なイベントの検出を変化点検知問題として定式化する.
- 5) **人間の活動分析**: スマートホームまたはモバイルデバイスにより測定されたセンサデータに基づき, 活動認識や行動認識を行うことを変化点検知問題として定式化する.

Aminikhanghahi and Cook[106]は変化点検知を機械学習と同様に, 教師あり変化点検知と教師なし変化点検知に分類した.

教師あり変化点検知は多クラス分類器, バイナリクラス分類器と仮想分類器に大別される. 多クラス分類器は事前に状態の数が定義されており, その各状態の境界を見つけるように学習される. 時系列データを分割するためにスライド窓 (sliding window) が用いられる. 多クラス分類器の訓練フェーズは比較的単純だが, 全てのクラスを識別するためには十分かつ多様な訓練データを用意する必要がある. 多クラス分類器の例として, 決定木, 最近傍, サポートベクタマシン, ナイーブベイズ, ベイジアンネットワーク, 隠れマルコフモデル, 条件付き確率場, 混合ガウスモデルが挙げられる. 別の方法として, 変化点検出をバイナリクラス分類問題として扱う方法がある. この場合, 変化点はすべて1つのクラスに属し, それ以外のデータはもう1つのクラスに属す. この場合, 2つのクラスのみを学習する必要があるが, 遷移する可能性のあるクラスが多くなる場合, はるかに複雑な学習問題となる[106]. バイナリクラス分類では, 入力ベクトルの各特徴が起こり得る変化の原因を示す. バイナリクラス分類には, サポートベクタマシン, ナイーブベイズ, ロジスティック回帰が含まれる. ただし, 変化点を示すデータシーケンスよりも, それ以外のデータシーケンスの方がはるか

に多いため、極端なクラスの不均衡が問題点として存在する。

教師なし学習アルゴリズムは通常、ラベルの無いデータのパターンを発見するために使用される。変化点検知では、教師なし学習アルゴリズムを使用して時系列データをセグメント化し、データの統計的特徴に基づいて変化点を検出する。教師なし学習アルゴリズムの利点は、状況ごとに事前の訓練を必要とせず様々な状況に適用できることである。主な手法として、尤度比に基づく手法、部分空間モデリングに基づく手法、確率的手法、カーネルベースの手法、グラフベースの手法、クラスタリングに基づく手法などがある。

尤度比を用いた変化点検知は、初めに 2 つの連続するデータシーケンスの確率密度をそれぞれ計算し、その後、それらの確率密度の比率が計算される。最もよく知られている手法は累積和に基づく手法で、これは入力値の指定されたターゲットデータに対する偏差を累積し、累積和が指定されたしきい値を超えた時に変化点が存在することを示す。Change Finder は、変化点検知の問題を時系列データベースの外れ値検知へ落とし込む尤度比を用いた変化点検知でしばしば使用される手法である。これらの手法は事前に定義されたパラメトリックモデルに依存するため、実際の変化点検知においては柔軟性が低いため、近年では、密度推定を実行せずに確率密度の比率を直接推定することで、ノンパラメトリックのモデルへ展開し、より柔軟に変化点の検出を行っている。代表的な手法として、Kullback-Leibler importance estimation procedure, unconstrained least-squares importance fitting (uLSIF), relative uLSIF, semi-parametric log-likelihood change detector などが知られている。

部分空間モデリングは状態空間を使用して時系列を表し、状態空間パラメータを予測することによって変化点を検出するアプローチで、制御理論の分野で研究されてきたシステム同定法と強い関連がある。代表的な手法は、subspace identification と特異スペクトル変換 (singular spectrum transformation) である。これらの部分空間モデルの手法はどちらも事前に定義されたモデルに基づいているが、特異スペクトル変換はシステムに対するノイズの影響を考慮していないため、パラメータ値の選択によって結果が左右されやすい。

確率的手法は直前の変化点以降に観測されたデータに基づいて、新しい区間の確率分布を推定する。代表的な手法として、Bayesian change point detection やガウス過程 (Gaussian process) に基づく手法などが知られている。

カーネルベースの手法は観測値を高次元の特徴空間に写像し、各部分時系列の均一性を比較することによって変化点を検出する。一般的にカーネルベースの手法は教師あり学習手法として使用されるが、一部の研究で、教師なし学習として用いられている。

グラフベースの手法は時系列の観測値をグラフとして表現し、統計的検定を適用して変化点を検出する比較的新しい手法である。グラフは通常、サンプル空間の距離または一般化された非類似度から導出され、時系列の観測値はノードとして、エッジはそれらの距離に基づいて観測値を接続する。後述するグラフィカル Lasso アルゴリズムは観測値が正規分布に従うという仮定の下で、各変数間の関係をグラフ構造として捉えるため、Aminikhanghahi and Cook[106]の論文内で述べられているグラフベースの手法がノンパラメトリックの手法であ

ることから前提条件が異なる。

クラスタリングに基づく手法は時系列データをそれぞれの状態にグループ化し、状態の特徴間の違いを識別することによって変化点を検出する。代表的な手法として、**sliding window and bottom-up**, **Minimum Description Length**, **Shaplet** 特徴量に基づく手法、モデルフィッティングに基づく手法などが存在する。

- ・ 特異スペクトル変換

特異スペクトル変換は、**Ide and Inoue[107]**によって 2004 年に提案された変化点スコアに基づいて元の時系列データを新しい時系列データへ変換するアルゴリズムである。類似手法として、**Moskvina and Zhigljavsky[108]**によって 2003 年に提案された特異スペクトル解析 (**singular spectrum analysis**) が知られている。これら 2 つの手法は特異値分解 (**singular value decomposition**) を用いてデータの特徴を抽出するという点で類似しているが、いくつかの点で相違がある。最も顕著な違いとして、特異スペクトル変換が特異値分解を行い得られる特徴を比較し、変化度合いをスコア化し、そのスコアに基づいた新しい時系列データに変換するのに対し、特異スペクトル解析では、特異値に基づいてデータを構成する主成分のみを抽出し、不要な情報を取り除いたデータを再構築することが目的であるという点が挙げられる。特異値分解は人間の動作解析にしばしば用いられている。高橋ら[109]や三嶋ら[110]は、特異値分解を用いて個人の類似動作や個人ごとに異なる動作 (個人特徴) の抽出を行った。林ら[111]は関節モーメントに対し特異値分解を適用し被験者間の相違点を示す主要な運動パターンの抽出を行った。特異スペクトル解析は音信号からの工具摩耗の検出[112]、旋削加工における振動信号の処理[113]、工具摩耗モニタリング時のノイズ除去[114]などの機械の稼働監視に用いられている。さらに人間工学および生理学分野では、モーションキャプチャで計測された運動信号の平滑化[115]、脳波および心電図からのノイズ除去[116][117]、歩行パラメータの推定[118]、筋電図信号の開始点の検出[119]などに用いられている。特異スペクトル変換は人間の動作の解析にもしばしば用いられる。例えば、徳永ら[120]は特異スペクトル変換により得た動作変化点を変化部位を表すアルファベット 1 文字に変換した動作変化点列を生成する手法を提案している。**Tamura et al.[121]**は指のジェスチャ動作の認識のために特異スペクトル変換を応用している。

- ・ スパース構造学習に基づく異常検知手法

多変量の変数で表される系の監視業務などでは、個々の異常事象に対する各変数の寄与度を知ることが重要である。**Ide et al.[122]**はこうした問題に対して、変数同士の密接な類似性を「近傍」と定義し、その近傍が正常に稼働している系同士においては、実験条件のばらつきに対して、各変数の近傍グラフがほとんど不変であるという仮説に基づき、相関異常を検知する問題を各変数の近傍グラフの変化を定量的にとらえる問題と定義した。代表的な近傍グラフはガウシアングラフィカルモデルである。このモデルは、各変数を頂点とし、あ

る変数間をつなぐ辺がないことを両者は他の全ての変数を固定した時に条件付き独立であると定義する。確率分布と変数の関係を表すグラフが対応することで、グラフ構造をデータから学習する問題（構造学習（structure learning）と呼ばれる）が、データから確率分布を学習する問題に帰着される。統計学の分野では、実数値多変量データからの構造学習という問題は、Dempster[123]をはじめとする共分散構造選択理論の枠組みで扱われてきた。その名の通りこの理論は、多変量正規分布を仮定して、疎な構造を実現するためのある制約の下に、データに対して精度行列（共分散行列の逆行列）を反復的に当てはめる。しかし実データへ応用する上では、逆行列が存在しないデータには使用できない点や計算コストが高いこと、統計的検定の観点で必ずしも最適でないことなどの欠点が知られていた。近年、伝統的な共分散構造選択方の欠点を解決する目的で、新たな疎構造学習の手法がいくつか提案されている。中でも Meinshausen and Bühlmann[124]は、疎構造学習というタスクを各変数の近傍選択の問題としてとらえ、それを1つの変数を目的変数とし残りを説明変数とする Lasso (L_1 制約付き線形回帰) の問題として定式化した。さらに、Friedman et al.[125]はグラフィカル Lasso と呼ばれる劣勾配アルゴリズムを提案した。 L_1 正則化により、多くの線形結合の係数は厳密にゼロとなり、非ゼロの係数を持つ説明変数は目的変数の近傍とみなされる。実用的な観点からは、グラフィカル Lasso の利点の1つは、変数の数が標本の数が大きいような状況でも形式的には疎構造学習が可能であるという点である。これまでの共分散選択手法では、共分散行列がランク欠損を起こしているような状況では意味のある結果を出すことが困難であったため、グラフィカル Lasso の利点は実データへ応用する上で非常に強い利点であった。そしてグラフィカル Lasso に基づいて各変数の寄与を計算する一連のアルゴリズムが Ide et al.[122]により提案された。

実際のグラフィカル Lasso の応用例として、Sun et al.[126]はグラフィカル Lasso とニューラルネットワークを用いた交通量の予測手法を提案した。Li et al.[127]は画像分類において、ラベルの相関関係を利用するために、画像の特徴を考慮し、画像に依存する条件付きラベル構造学習を行うために、条件付きグラフィカル Lasso を開発した。また、Yan et al.[128]は人間の脳機能の個人差を定量化するためにグラフィカル Lasso を応用している。

1.2 研究目的

機械による自動化が進む現在の作業現場において、人間の作業は問題解決能力を要する複雑なタスクか低負荷・高反復作業へと変化している。そのため、わずかな作業姿勢および動作の違いを検出し、身体負担や作業性を定量的に評価することができる手法の構築が望まれる。そこで、近年発展が進む機械学習や AI などの計算技術の応用が期待される。しかし、作業者の熟練度や身体特性などの様々な要因によって作業姿勢および動作が変化することから正解となる教師データを定義することが困難なため、教師データを用いない教師なし学習アルゴリズムの 1 つである異常検知手法に着目する。計算機能力の向上に伴い、様々な異常検知アルゴリズムが提案され、広範な分野へ応用されている。人間工学分野でも、脳波や心電図、筋電図等の信号処理への応用や、動作の平滑化、動作の変化点検出などに応用されている。しかし、わずかな作業姿勢および動作の違いを検出し、身体負担や作業性を異常検知手法により評価するためには、いくつかの解決しなければならない課題がある。はじめに、異常検知手法の概要で述べたように、測定されたデータおよびそのデータ形式や検出したい異常に応じた適切な異常検知手法の選定が重要となる。次に、異常検知手法による評価結果と従来の人間工学評価による結果の関係について明らかにする必要がある。そして最後に、人間工学分野でしばしば議論される動作のばらつき[129]や関節の協調動作[130]などの人間の動作の特徴を考慮した異常検知手法の検討または提案を行う必要がある。

そこで、本研究では、実作業を想定したいくつかの作業場面において、作業姿勢や身体負担評価を行うなどの従来の人間工学評価を行うとともに、その場面に応じた異常検知手法を選択し、その有用性を従来の人間工学評価との関連から実験的に明らかにすることを目的とする。具体的には、平均値などの作業姿勢の代表値となる静止姿勢が収集された場面における作業姿勢の問題点の発見、作業姿勢の時系列データから突発的に生じる問題点の発見、反復作業における経時的な姿勢変化の検出、複数の関節の関係を考慮した姿勢変化の検出の 4 つの状況に対し、有用な異常検知手法の提案と従来の人間工学評価法などによる知見との関係を明らかにする。

1.3 本論文の構成

第1章では、本研究の背景と目的を明らかにした。第2章・第3章では、平均値などの作業姿勢の代表値となる静止姿勢が収集された場面において One-Class Support Vector Machine による評価の有用性を明らかにする。第2章では身体近傍のねじ締め作業を例に、作業域が制限され、関節角度や関節トルク比の変化は小さいものの、主観的な作業性には大きな影響を与える場面における One-Class Support Vector Machine の有用性を明らかにする。第3章では、保守点検作業等において障害物を回避しながら作業する場面のように、負荷の大きな姿勢の保持が強制されるような場面における One-Class Support Vector Machine の有用性を明らかにする。第4章では、作業中に突発的に発生するミスなどによる姿勢変化を特異スペクトル変換を用いて検出することができるか検討する。第5章では、反復作業における経時的な姿勢変化の検出のために、特異スペクトル変換を拡張し、その有用性を明らかにする。第6章では、関節の協調動作など複数の関節が連動して動作するような場面において、連動度合いの変化を1つの動作の特徴として定義し、スパース構造学習に基づく異常検知を用いて協調関係にある関節の抽出および異常スコアベースでの作業姿勢変化の検出を行う。第7章では、本論文の結論と今後の展望を示す。

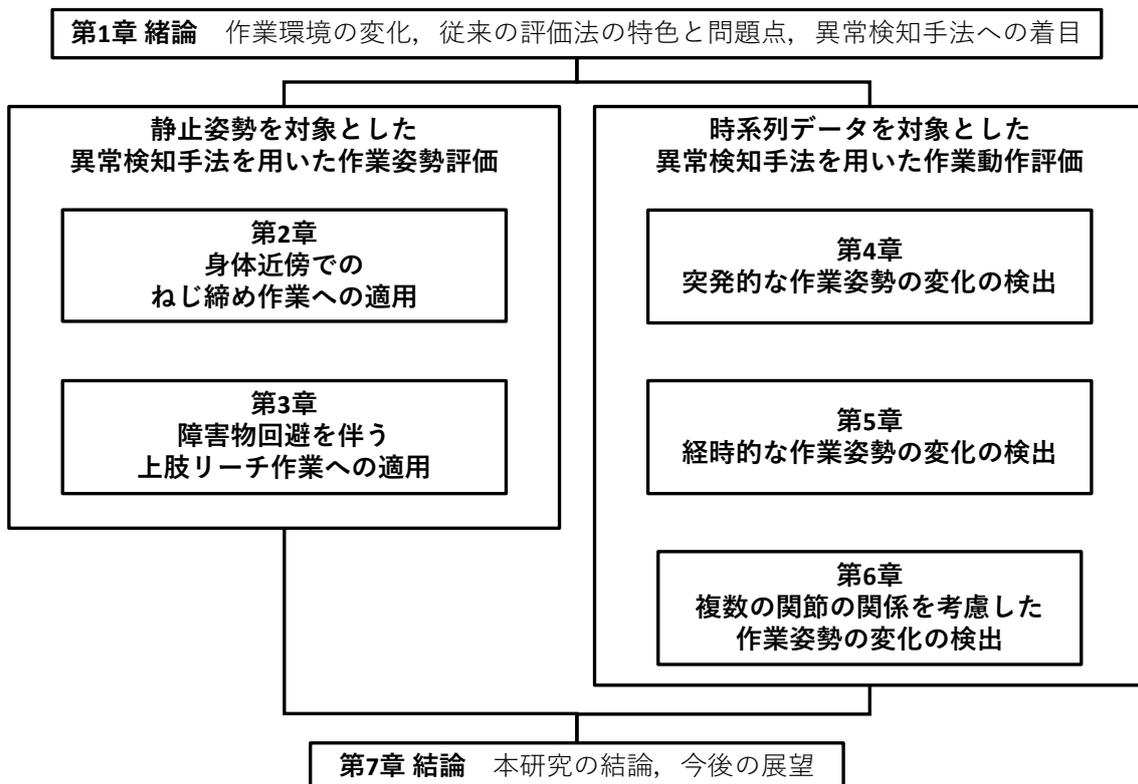


図 1.3.1 本論文の構成

第2章 静止姿勢を対象とした異常検知手法を用いた作業姿勢評価： 身体近傍でのねじ締め作業を対象とした One-Class Support Vector Machine の有用性の検証

2.1 緒論

人間工学領域では、作業姿勢や身体負担を評価するために、時系列データではなく、作業姿勢の代表値を取り扱う場面が多くみられる。例えば、観察法の1つであるOWASでは、ある時刻の作業姿勢を背部・上肢・下肢・重さの4項目でとらえ、コード化した数字で記録する[14]。またRULAでは、1日の作業全体を見て代表的な姿勢を決定し、上肢・頭部・体幹部・下肢の姿勢について角度に基づいてスコア付けして評価を行う[21]。生体力学解析においても、作業条件間や被験者間の作業姿勢・身体負担の比較を行う場合、平均値や中央値などの代表値が用いられる。したがって、従来の人間工学評価との関係から異常検知手法の有用性を明らかにするために、第2章および第3章では、平均値などの作業姿勢の代表値を含む静止姿勢を対象とした異常検知手法を用いた作業姿勢評価を試みる。

第2章および第3章では静止姿勢を対象とした異常検知手法として One-Class Support Vector Machine を用いる。One-Class Support Vector Machine は1クラス分類問題を扱うために通常のサポートベクタマシンを拡張したものである[95]。One-Class Support Vector Machine は障害の検出と診断[131]、患者の分類[132]、およびネットワークの侵入検知[133]などで利用されている。これまでにサポートベクタマシンを使用して人間の動きや活動の分析を行った先行研究[134][135]は報告されているが、One-Class Support Vector Machine を人間の作業姿勢や動作の異常の検出のために応用した研究は未だなく、従来の人間工学評価法との関係から有用性を評価する必要がある。

本章では、作業域が制限されているため関節角度の変化が小さく、従来までの関節角度や関節トルク比の評価では差を明らかにすることは難しいが、作業性の主観評価には影響が出やすい身体近傍での作業に着目する。そこで、低負荷かつ身体近傍で実施することにより作業性に大きな影響を与える作業の例として、作業位置と作業高さを変更した身体近傍でのねじ締め作業を対象に One-Class Support Vector Machine の有用性を明らかにすることを本章の目的とする。具体的には、作業位置条件6条件、作業高さ条件3条件を組み合わせた実験を行い、従来の人間工学評価として関節角度、関節トルク比、作業のしにくさについて測定し、One-Class Support Vector Machine による姿勢分類結果と比較した。従来の人間工学評価の傾向との比較に基づき、One-Class Support Vector Machine による姿勢分類結果の妥当性および有用性を評価する。

2.2 理論

2.2.1 One-Class Support Vector Machine の概要

One-Class Support Vector Machine は 1 クラス分類問題を扱うために, Schölkopf et al.[95]によって提案された手法である. One-Class Support Vector Machine はデータ空間において正しいデータを含む領域を推定し, 推定された領域内のデータを外れ値とみなす教師なし学習アルゴリズムである.

One-Class Support Vector Machine によって記述される対象データ $\mathbb{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$ が, 元の特徴空間から新しい特徴空間 \mathcal{H} に写像する陰関数 $\Phi(\cdot)$ であるとする. N はデータの総数を示す. この時, One-Class Support Vector Machine は, 以下の式で求める超平面を求める.

$$\Pi: \mathbf{w}^T \Phi(\mathbf{x}) - \rho = 0. \quad (2.1)$$

この超平面は, 原点から最大マージンを持つよう設定される. 写像された対象データ $\Phi(\mathbf{x})$ は原点から超平面の反対側に写像される. これらの目的関数は以下の最適化問題として定義される.

$$\begin{aligned} \min_{\mathbf{w}, \xi, \rho} & \frac{1}{2} \|\mathbf{w}\|^2 + \frac{1}{\nu N} \sum_{i=1}^N \xi_i - \rho, \\ \text{s. t.} & \quad \mathbf{w}^T \Phi(\mathbf{x}_i) - \rho + \xi_i \geq 0, \quad \xi_i \geq 0, \quad \forall i. \end{aligned} \quad (2.2)$$

ここで, ν は対象データに含まれる外れ値の上限を示し, ξ_i は, One-Class Support Vector Machine にソフトマージンを持たせるためのスラック変数である. $\Phi(\cdot)$ は陰関数であるため, 上記の最適化問題は通常, 陰関数の二重形式によって示される.

$$\begin{aligned} \max_a & -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j K(\mathbf{x}_i, \mathbf{x}_j), \\ \text{s. t.} & \quad \sum_{i=1}^N \alpha_i = 1, \quad 0 \leq \alpha_i \leq \frac{1}{\nu N}, \quad \forall i. \end{aligned} \quad (2.3)$$

ここで, $K(\mathbf{x}_i, \mathbf{x}_j) = \Phi(\mathbf{x}_i)^T \Phi(\mathbf{x}_j)$ は写像したデータの内積であり, α_i は二重変数である. 実際は, 写像 $\Phi(\mathbf{x})$ の代わりにカーネル関数 $K(\mathbf{x}_i, \mathbf{x}_j)$ を直接指定する. これまでに様々なカーネル関数が提案されているが, 本研究では代表的なカーネル関数の 1 つであるガウシアンカーネルを用いる.

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{\sigma^2}\right). \quad (2.4)$$

ここで、 σ はガウスクERNEL幅と呼ばれ、決定境界の滑らかさを制御する変数である。ただし、最適なパラメータを選択しなければ One-Class Support Vector Machine の対象データに含まれるノイズの影響をあいまいにする、すなわちノイズに対する感度が低下する。Kernel関数とハイパーパラメータを用いて、式(2.3)の二重最適化問題は、二次計画問題として解くことができる。 ρ は $0 \leq \alpha_i \leq \frac{1}{vN}$ を満たす α_i と一致する任意の \mathbf{x}_i を選択することによって得ることができ、以下の式(2.5)で計算される。

$$\rho = \sum_{j=1}^N \alpha_j K(\mathbf{x}_i, \mathbf{x}_j). \quad (2.5)$$

対応する $\alpha_i > 0$ を持つ \mathbf{x}_i はサポートベクトルと呼ばれ、One-Class Support Vector Machine の決定境界をサポートする。データ中の外れ値は、以下の式(2.6)を満たすとき外れ値として決定される。

$$f(\mathbf{x}) = \sum_{\alpha_i > 0} \alpha_i K(\mathbf{x}_i, \mathbf{x}_j) - \rho < 0. \quad (2.6)$$

2.2.2 作業姿勢の分類への応用

本研究で提案する One-Class Support Vector Machine を用いた作業姿勢の分類手順を以下に示す。

- Step 1. 複数の被験者を対象に異なる作業条件で作業姿勢（各身体セグメントのオイラー角）を計測する。
- Step 2. 計測した各身体セグメントのオイラー角をクォータニオンへ変換する。
- Step 3. 各身体セグメントのクォータニオンを用いて、One-Class Support Vector Machine による作業姿勢の分類を行う。
- Step 4. 観測値の総数に対する異常観測数の比率を各実験条件について計算する。

各実験条件間で異常値の比率を比較するために、異常率を次の式を使用して計算する。

$$\theta = \frac{m}{N} \quad (2.7)$$

ここで、 m は One-Class Support Vector Machine によって抽出された異常姿勢の数を表し、 N は One-Class Support Vector Machine に学習された観測値の総数を示す。

オイラー角 (Euler angle) は、剛体の運動を考える時、剛体が現在どのような方位関係を持っているのかを 3 つの角度を使用して表現するものである。しかし人間の姿勢表現において、オイラー角の採用にはいくつかの問題がある。例えば、特異姿勢において、ジンバルロックが生じ角度表現の一意性が担保されなくなることや、その近傍の姿勢では、わずかな姿勢変化でも算出される角度の値が大きく変化する場合がある。これらの要因に伴い数値的な誤差も過大評価されることがある。本研究で計測した各身体セグメントのオイラー角についてもジンバルロックなどの問題が生じる可能性があることに加え、3次元の姿勢では、各関節が持つ自由度が相互に関係しながら変化する。そのため、個々の自由度の観察では把握できないような特徴的な状況が見落とされる可能性がある。そこで本研究では、このような問題を解消するためにクォータニオンを用いる。クォータニオンは虚数を拡張したものであり、回転において 3 自由度が相互に変化する特徴的な状況でも連続的な観察を可能にするものである。クォータニオンを用いた作業姿勢の異常検知を試みるために、計測したオイラー角をクォータニオンへと変換する。

本研究では、Step 3.において入力する特徴ベクトルを以下のように変更した。

- 1) 全ての身体セグメントのクォータニオンを 1 つの特徴ベクトルとして定義
- 2) 身体セグメントそれぞれのクォータニオンを特徴ベクトルとして定義

オイラー角のクォータニオンへの変換にはいくつかの手法が存在する。以下には、代表的な変換方法について述べる。

2.2.2.1 オイラー角から方向余弦行列を求め、クォータニオンを導出する方法

x, y, z 軸周りの回転角をそれぞれロール ϕ 、ピッチ θ 、ヨー ψ と定義した時、各軸周りの回転行列 $\mathbf{R}_x, \mathbf{R}_y, \mathbf{R}_z$ はそれぞれ以下のように定義される。

$$\mathbf{R}_x = \begin{pmatrix} 1 & 0 & 0 \\ 0 & \cos \phi & \sin \phi \\ 0 & -\sin \phi & \cos \phi \end{pmatrix}, \mathbf{R}_y = \begin{pmatrix} \cos \theta & 0 & \sin \theta \\ 0 & 1 & 0 \\ -\sin \theta & 0 & \cos \theta \end{pmatrix}, \mathbf{R}_z = \begin{pmatrix} \cos \psi & \sin \psi & 0 \\ -\sin \psi & \cos \psi & 0 \\ 0 & 0 & 1 \end{pmatrix}. \quad (2.8)$$

各セグメントの方向余弦行列は各軸周りの回転行列 $\mathbf{R}_x, \mathbf{R}_y, \mathbf{R}_z$ を合成した行列 \mathbf{E} として定義される。この時、合成の順序は、同じ軸周りの回転を 2 回使う場合もあり、合計で 12 通り存在する。例として、ロール $\phi \rightarrow$ ピッチ $\theta \rightarrow$ ヨー ψ の順で回転させた場合の方向余弦行列 \mathbf{E} を以下に示す。

$$\begin{aligned}
\mathbf{E} &= \mathbf{R}_x \mathbf{R}_y \mathbf{R}_z \\
&= \begin{pmatrix} 1 & 0 & 0 \\ 0 & \cos \phi & \sin \phi \\ 0 & -\sin \phi & \cos \phi \end{pmatrix} \begin{pmatrix} \cos \theta & 0 & \sin \theta \\ 0 & 1 & 0 \\ -\sin \theta & 0 & \cos \theta \end{pmatrix} \begin{pmatrix} \cos \psi & \sin \psi & 0 \\ -\sin \psi & \cos \psi & 0 \\ 0 & 0 & 1 \end{pmatrix} \\
&= \begin{pmatrix} \cos \theta \cos \psi & \cos \theta \sin \psi & -\sin \theta \\ \sin \phi \sin \theta \cos \psi - \cos \phi \sin \psi & \sin \phi \sin \theta \sin \psi + \cos \phi \cos \psi & \sin \phi \cos \theta \\ \cos \phi \sin \theta \cos \psi + \sin \phi \sin \psi & \cos \phi \sin \theta \sin \psi - \sin \phi \cos \psi & \cos \phi \cos \theta \end{pmatrix} \quad (2.9)
\end{aligned}$$

クォータニオン \mathbf{q} は回転方向の単位ベクトル \mathbf{n} と回転角 θ の 4 成分で定義され、以下の式で表される。

$$\mathbf{q} = \cos \frac{\theta}{2} + \mathbf{n} \sin \frac{\theta}{2}. \quad (2.10)$$

ここで、クォータニオンの定義から明らかな通りノルムは 1 ($\sum_{i=1}^4 q_i = 1$) である。

方向余弦行列からクォータニオンを求めるためには、まず、方向余弦行列の対角項からクォータニオンの 1 変数を求め、次に求めた変数を用いて他の変数を計算する。対角項から q_4 を求めたときは、以下の通りとなる。

$$q_4 = \pm \frac{1}{2} \sqrt{1 + E_{11} + E_{22} + E_{33}}, \quad (2.11a)$$

$$q_1 = \frac{1}{4q_4} (E_{23} - E_{32}), \quad (2.11b)$$

$$q_2 = \frac{1}{4q_4} (E_{31} - E_{13}), \quad (2.11c)$$

$$q_3 = \frac{1}{4q_4} (E_{12} - E_{21}). \quad (2.11d)$$

ここで、 $\mathbf{E} = \begin{pmatrix} E_{11} & E_{12} & E_{13} \\ E_{21} & E_{22} & E_{23} \\ E_{31} & E_{32} & E_{33} \end{pmatrix}$ である。ただし、方向余弦行列の対角項からクォータニオンの 1 変数を選ぶ際は、変数がゼロにならないようなものにしなければならない。

2.2.2.2 各軸周りに回転するクォータニオンを定義し，3次元回転を計算する手法

x, y, z 軸周りの回転角をそれぞれロール ϕ ，ピッチ θ ，ヨー ψ と定義した時，各軸周りの回転クォータニオン \mathbf{q}_x ， \mathbf{q}_y ， \mathbf{q}_z はそれぞれ以下のように定義される．

$$\mathbf{q}_x = \begin{bmatrix} q_{x,0} \\ q_{x,1} \\ q_{x,2} \\ q_{x,3} \end{bmatrix} = \begin{bmatrix} \cos \frac{\phi}{2} \\ \sin \frac{\phi}{2} \\ 0 \\ 0 \end{bmatrix}, \mathbf{q}_y = \begin{bmatrix} q_{y,0} \\ q_{y,1} \\ q_{y,2} \\ q_{y,3} \end{bmatrix} = \begin{bmatrix} \cos \frac{\theta}{2} \\ 0 \\ \theta \\ \sin \frac{\theta}{2} \\ 0 \end{bmatrix}, \mathbf{q}_z = \begin{bmatrix} q_{z,0} \\ q_{z,1} \\ q_{z,2} \\ q_{z,3} \end{bmatrix} = \begin{bmatrix} \cos \frac{\psi}{2} \\ 0 \\ 0 \\ \sin \frac{\psi}{2} \end{bmatrix}. \quad (2.12)$$

Z-Y-X の順で変換すれば，3次元のクォータニオン \mathbf{q} は下記の式で計算することが可能．

$$\begin{aligned} \mathbf{q} = \mathbf{q}_z \mathbf{q}_y \mathbf{q}_x &= \begin{bmatrix} \cos \frac{\psi}{2} \\ 0 \\ 0 \\ \sin \frac{\psi}{2} \end{bmatrix} \begin{bmatrix} \cos \frac{\theta}{2} \\ 0 \\ \sin \frac{\theta}{2} \\ 0 \end{bmatrix} \begin{bmatrix} \cos \frac{\phi}{2} \\ \sin \frac{\phi}{2} \\ 0 \\ 0 \end{bmatrix} \\ &= \begin{bmatrix} \cos \frac{\phi}{2} \cos \frac{\theta}{2} \cos \frac{\psi}{2} + \sin \frac{\phi}{2} \sin \frac{\theta}{2} \sin \frac{\psi}{2} \\ \sin \frac{\phi}{2} \cos \frac{\theta}{2} \cos \frac{\psi}{2} - \cos \frac{\phi}{2} \sin \frac{\theta}{2} \sin \frac{\psi}{2} \\ \cos \frac{\phi}{2} \sin \frac{\theta}{2} \cos \frac{\psi}{2} + \sin \frac{\phi}{2} \cos \frac{\theta}{2} \sin \frac{\psi}{2} \\ \cos \frac{\phi}{2} \cos \frac{\theta}{2} \sin \frac{\psi}{2} - \sin \frac{\phi}{2} \sin \frac{\theta}{2} \cos \frac{\psi}{2} \end{bmatrix}. \end{aligned} \quad (2.13)$$

2.2.3 One-class Support Vector Machine のハイパーパラメータの設定

本研究ではガウシアンカーネルを用いるため，One-Class Support Vector Machine のハイパーパラメータは σ と ν となる．ハイパーパラメータの選択方法には主に2つの手法が用いられている[136]．1つは疑似外れ値生成に基づく手法で，特徴点を無作為に選択された値に置き換え，人工的な異常を生成する．しかしこの手法では，最適な外れ値を選択するとは限らないことや特徴の次元の増加につれて必要な疑似外れ値の数が増加するなどの欠点がある．もう1つの手法はヒューリスティックベースの手法である．この手法はOne-Class Support Vector Machine の良好なハイパーパラメータが通常，直感的な観察や経験的な事前知識を満たしているという仮定に基づいてハイパーパラメータの選択を行う．本研究ではヒューリスティックベースのハイパーパラメータ選択方法を用いて，外れ値の割合を決めるパラメータである ν を変更し，異常姿勢の検出の傾向について確認する． σ の値は，MATLAB R2017b の Statistics and Machine Learning Toolbox 内の `fitsvm` 関数のデフォルト値を使用する．

2.3 実験方法

2.3.1 被験者

被験者は右利きの学生 12 名（男性 6 名，女性 6 名）であった。被験者の年齢，身長，体重の平均±標準偏差は， 22.9 ± 1.1 歳， 1649 ± 71 mm， 58.1 ± 7.8 kg であった。また，前腕長（肘頭から指尖点間までの直線距離）および手長（手掌面で手掌に最も近い屈曲線から指尖点までの直線距離）の平均±標準偏差は， 257 ± 21 mm， 171 ± 17 mm であった。なお，本実験は首都大学東京日野キャンパスの研究安全倫理委員会の承認を得て実施した。実験を始める前に被験者に実験の概要を説明して書面による同意を得た。

2.3.2 実験条件

立位での身体近傍でのねじ締め作業を想定した作業として，三脚（004JB，Manfrotto 社）の高さ調整用の直径 2 cm のノブを締める作業を実施した。締め作業に必要なトルクは 8.0×10^{-3} Nm であり，締めトルクによる身体負担の過度な増加はない。実験条件は作業位置条件および作業高さ条件を組み合わせた図 2.3.1 に示す全 18 条件とした。作業位置条件は作業位置の距離 2 水準（遠距離，近距離）と水平方向の位置 3 水準（左，中央，右）を組み合わせた計 6 水準とした。作業位置の距離は右外果を基準とし，そこから前腕長の距離を遠距離，手長の距離を近距離と設定した。水平方向の位置は被験者の右外果の位置を中央とし，左右肩峰間距離だけ左右に離れた位置を左，右とそれぞれ定義した。高さ条件は被験者の肩高，肘高，腰高の 3 水準とした。

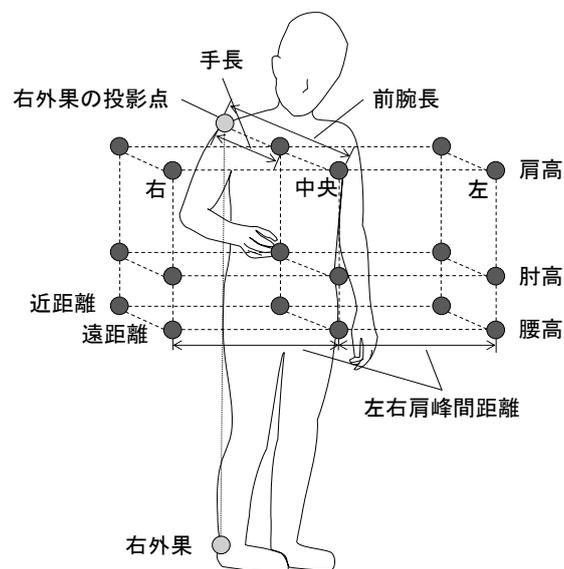


図 2.3.1 作業位置条件および作業高さ条件の組み合わせ

2.3.3 実験手順

実験開始前、被験者は立位で上肢を下垂した状態で待機した姿勢（以下、自然姿勢）を取った。実験の開始の合図に合わせて自然姿勢で5秒間静止し、その後5秒間、立位姿勢にて両手を真横に広げたTポーズを取った。このTポーズを取ることによって計測ソフトウェア（Motive, NaturalPoint社）で被験者の人体モデルが認識される。次の5秒間で、被験者は右手の甲を上に向けノブをつまむ姿勢を形成した。そして次の10秒間で、高さ調整用ノブ締め作業を実施した。ノブ締め作業は2秒に1回（10秒間で5回）ノブを回すように被験者に教示した。その後5秒間、被験者はノブから手を離し、自然姿勢に戻った。最後に5秒間自然姿勢を保持し、1試行が終了した。1試行は35秒とし、1条件につき3試行実施した。1条件が終了するごとに被験者は主観評価について回答した。なお、実験の実施順序は、順序効果による影響を排除するために被験者毎にランダム化して実施した。

2.3.4 計測項目および解析方法

2.3.4.1 作業姿勢（各身体セグメントのオイラー角・関節角度）および関節トルク比

実験中の作業姿勢を光学式モーションキャプチャシステム（OptiTrack, NaturalPoint）を用いて計測した。実験スペースを10台のカメラ（OptiTrack FLEX:V100R2, NaturalPoint）で囲み、実験開始前に計測ソフトウェアに指示されたキャリブレーションを実施した。被験者にはあらかじめキャプチャスーツを着用させ、図2.3.2に示す計測ソフトウェアに指示されたマーカ貼付位置にマーカを貼付した。それぞれのカメラによって撮影されたマーカの2次元座標を計測ソフトウェアを用いて計測し、カメラの位置情報を統合してサンプル点ごとに3次元座標へと変換した。その後、あらかじめ計測しておいたスケルトンボディと呼ばれる被験者の体格情報とマーカ座標位置との関係から、各身体セグメントの位置を推定する。そして、得られた被験者の各身体セグメントの全身の3次元座標情報をBVH（Biovision Hierarchy）ファイル形式で出力した。

出力されたBVHファイルは、当研究室開発の生体力学解析ソフトウェアの3次元剛体リンクモデルに当てはめ、各身体部位の傾きを算出した。そして、腹部、胸部、頸部、頭部、右肩、右上腕、右前腕の親リンクのローカル座標系に対する相対オイラー角を算出した。また、各身体部位の傾きから、体幹部および右上肢の関節角度を算出した。

計測された関節角度とChaffin et al. [35]および阿江ら[137]によって報告されている上肢セグメント長、セグメント質量、重心位置のデータを用いて関節に生じるトルクを推定した。推定された関節トルクを、各関節が発揮できる最大トルク[138]で正規化したものを関節トルク比と定義した。

2.3.4.2 主観評価

作業による主観的な負担感を明らかにするために、各条件の終了後に上肢および腰部の負担感について Borg CR10[139]を用いて口頭で回答させた。また、主観的な作業のしにくさについて、0（非常に作業しやすい）～10（非常に作業しにくい）の11段階で口頭で回答させた。

2.3.4.3 統計処理

統計解析は各指標を目的変数、作業位置条件（6水準）と作業高さ条件（3水準）を要因とした反復測定による二元配置分散分析で解析した。また、下位検定として Tukey 法による多重比較検定を行った。なお、全ての統計解析において危険率 5%を有意水準とした。

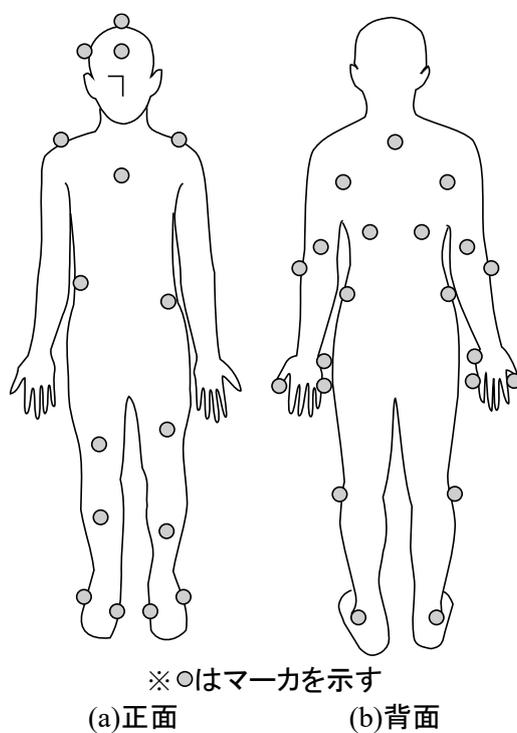


図 2.3.2 マーカ貼付位置

2.4 結果

2.4.1 関節角度

図 2.4.1 に示す体幹前傾角は作業位置が左や中央だと、近距離・遠距離によらず、作業高さが高いほど体幹部が後傾していた。分散分析では、高さ条件の主効果および作業位置条件と高さ条件の交互効果が有意であった[高さ： $F(2, 215)=8.15, (p<0.001)$ ，作業位置×高さ： $F(10, 215)=3.40, (p<0.001)$]。

図 2.4.2 の体幹部右傾角は作業位置が左や中央だと、近距離・遠距離によらず、体幹部が左傾していた。作業位置が右の場合、体幹右傾角の変化は小さく、直立姿勢に近かった。分散分析では、作業位置条件の主効果が有意であった[$F(5, 215)=8.81, (p<0.001)$]。

図 2.4.3 の体幹部左旋角は作業位置が右や中央だと体幹部は右旋，作業位置が左だと左旋していた。分散分析では作業位置条件の主効果が有意であった[$F(5, 215)=197.8, (p<0.001)$]。

図 2.4.4 の右肩関節外転角は作業位置が右や中央だと、作業高さが高いほど大きく外転した。作業位置が左だと、作業高さが高いほど大きく内転していた。分散分析では、作業位置条件と高さ条件の主効果が有意であった[作業位置： $F(5, 215)=147.6, (p<0.001)$ ，高さ： $F(2, 215)=73.0, (p<0.001)$]。

図 2.4.5 の右肩関節屈曲角は遠距離で肩関節が屈曲する傾向にあった。作業位置が右だと、全ての高さ条件で肩関節が伸展していた。作業位置が左だと、高さ条件が低いほど屈曲角はやや減少する傾向にあった。分散分析では、作業位置条件と高さ条件の主効果および作業位置条件と高さ条件の交互効果が有意だった[作業位置： $F(5, 215)=204.7, (p<0.001)$ ，高さ： $F(2, 215)=18.1, (p<0.001)$ ，作業位置×高さ： $F(10, 215)=7.30, (p<0.001)$]。

図 2.4.6 の右肘関節屈曲角は、全ての作業位置条件で作業高さが低くなるのに伴い減少した。作業位置が中央だと、各前後方向条件の中で最も肘関節を屈曲する傾向にあった。分散分析では、作業位置条件と高さ条件の主効果が有意であった[作業位置： $F(5, 215)=111.5, (p<0.001)$ ，高さ： $F(2, 215)=347.7, (p<0.001)$]。

2.4.2 関節トルク比

図 2.4.7 の腰部のトルク比は近距離かつ作業位置が左の時に、最もトルク比が大きくなった。高さ条件で比較すると、作業高さが低いほどトルク比は増加した。分散分析では、作業位置条件と高さ条件の主効果が有意であった[作業位置： $F(5, 215)=25.5, (p<0.001)$ ，高さ： $F(2, 215)=5.03, (p=0.0074)$]。

図 2.4.8 の右肩関節トルク比は作業位置が左の時に増加した。作業位置が右と中央の場合、遠距離でトルク比が増加した。作業高さが高いほどトルク比が増加した。分散分析では、作業位置と高さ条件の主効果および作業位置条件と高さ条件の交互効果が有意であった[作業位置： $F(5, 215)=119.5, (p<0.001)$ ，高さ： $F(2, 215)=85.9, (p<0.001)$ ，作業位置×高さ： $F(10, 215)=2.26, (p=0.0162)$]。

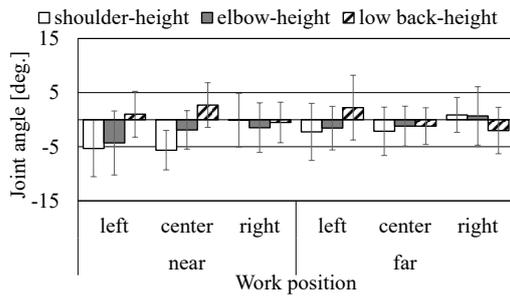


図 2.4.1 体幹前傾角

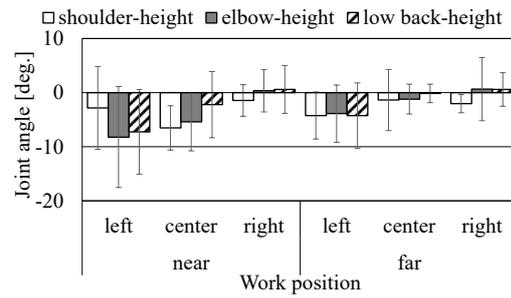


図 2.4.2 体幹右傾角

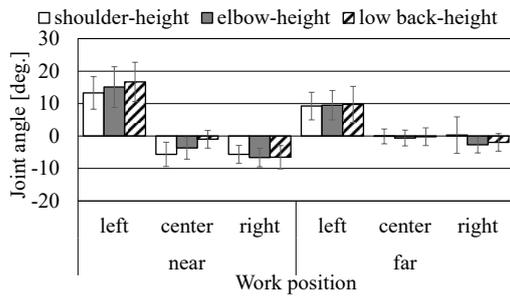


図 2.4.3 体幹左旋角

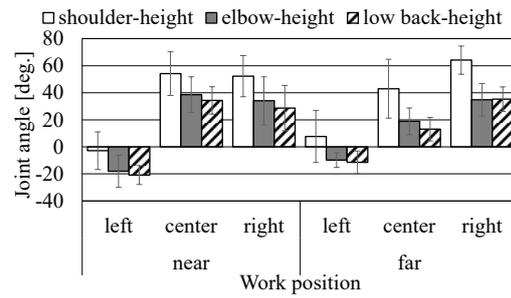


図 2.4.4 右肩関節外転角

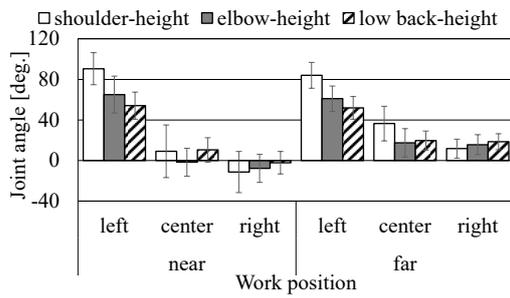


図 2.4.5 右肩関節屈曲角

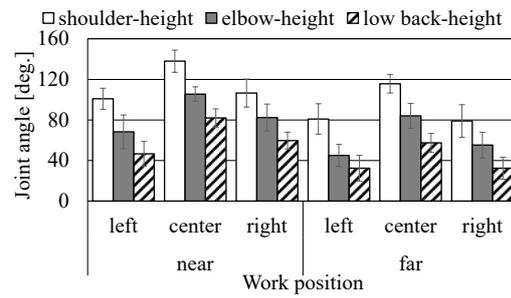


図 2.4.6 右肘関節屈曲角

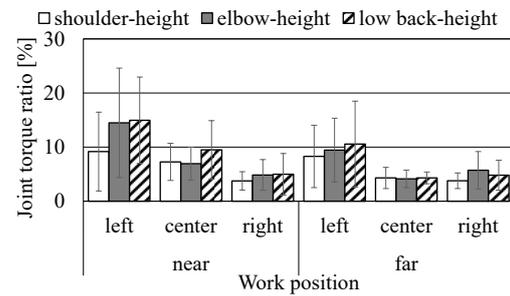


図 2.4.7 腰部関節トルク比

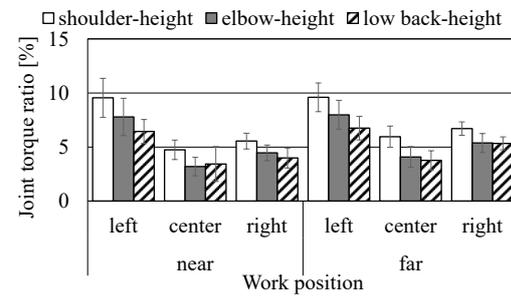


図 2.4.8 右肩関節トルク比

2.4.3 主観評価

図 2.4.9 の作業のしにくさは、近距離と遠距離の両条件において、作業位置が左の 때가最も作業しにくい条件であった。分散分析では、作業位置条件の主効果が有意だった[F(5, 215)=51.3, (p<0.001)].

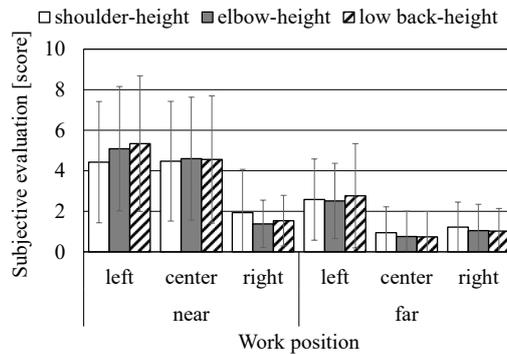


図 2.4.9 作業のしにくさ

2.4.4 One-Class SVM による姿勢の分類結果

2.4.4.1 任意の外れ値を設置した時の分類結果

図 2.4.10 に全ての身体セグメントのクォータニオンを 1 つの特徴ベクトルとして定義した時の 216 個の学習データ (=12 名×18 姿勢条件) に対する異常率を示す。 $\nu = 0.05$ とした時、近距離・左条件では異常率が増加した。また、近距離・中央条件にもいくつかの異常姿勢が検出された。遠距離では $\nu = 0.01$ の時と同様に、作業位置が右の時に異常姿勢が検出された。 $\nu = 0.10$ の時、異常率の最大値は $\nu = 0.05$ の時と変わらないが、近距離・左または近距離・中央条件において異常率が増加した。近距離・左条件では、 $\nu = 0.05$ では見られなかった肩高条件で異常姿勢が検出された。また、腰高条件で異常率が増加した。近距離・中央条件では、高さ条件に関わらず異常率は増加した。

図 2.4.11 に各部位ごとのクォータニオンを特徴ベクトルとして定義した時の異常率を示す。図において、体幹部は腹部と胸部の異常率の合計値、頭頸部は頸部と頭部の異常率の合計値、右上肢は右肩、右上腕、右前腕の異常率の合計値としている。 $\nu = 0.01$ の時には、条件による傾向は見られなかった。 $\nu = 0.05$ の時、近距離の方が遠距離よりも異常率が多い傾向にあり、作業位置が左の時に最も異常率が多い結果となった。

部位ごとに着目すると、頭頸部は作業高さが低くなるのに伴い、異常率が増加した。右上肢は作業高さが高くなるのに伴い異常率が増加した。 $\nu = 0.10$ とした時、近距離・左条件に次いで、異常率が他の条件と比較して、顕著に増加した。また、体幹部や右上肢などに見られた傾向は、 $\nu = 0.10$ の時でも同様に確認された。

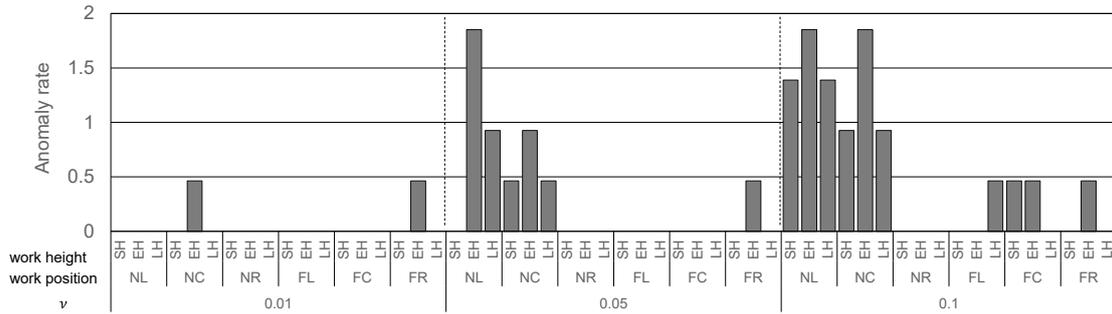


図 2.4.10 各部位のクォータニオンを1つの特徴ベクトルとした時の作業条件別の異常率
 ※図中の略字はそれぞれ以下の項目を示している。

SH：肩高，EH：肘高，LH：腰高，NL：近距離・左条件，NC：近距離・中央条件，NR：近距離・右条件，FL：遠距離・左条件，FC：遠距離・中央条件，FR：遠距離・右条件

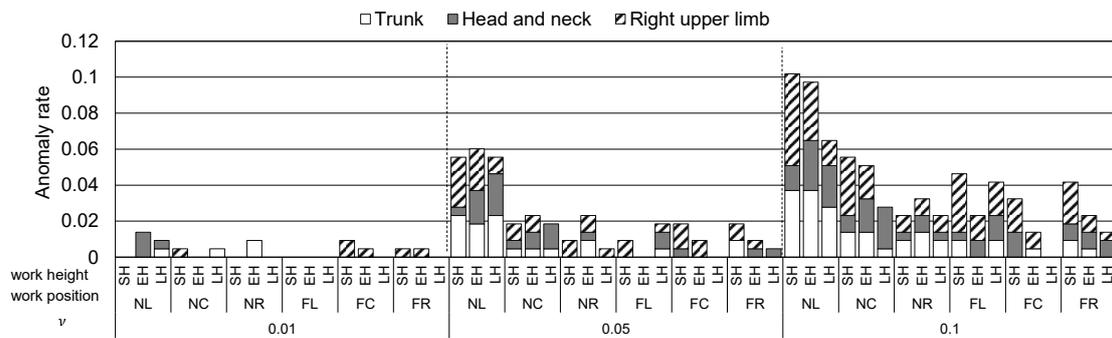


図 2.4.11 各部位のクォータニオンをそれぞれ特徴ベクトルとした時の作業条件別の異常率
 ※図中の略字はそれぞれ以下の項目を示している。

SH：肩高，EH：肘高，LH：腰高，NL：近距離・左条件，NC：近距離・中央条件，NR：近距離・右条件，FL：遠距離・左条件，FC：遠距離・中央条件，FR：遠距離・右条件

2.4.4.2 外れ値の上限を変化させた時の異常率

図 2.4.12 に $\nu = 0.01$ から $\nu = 0.25$ まで変化させたときの異常率の推移を示す。この結果から、異常率の傾向は $\nu = 0.05$ 付近から見え始め、 $\nu = 0.10$ の時に条件間の差が顕著に見られた。また、 $\nu = 0.10$ 以上になった時、条件間の差の変化はなくなった。

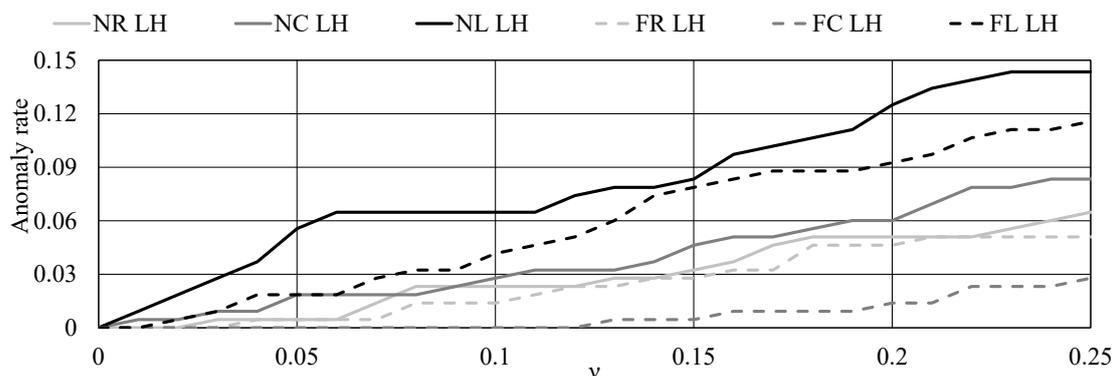


図 2.4.12 ν を変化させたときの異常率の推移

※図中の略字はそれぞれ以下の項目を示している。

- NR LH : 腰高・近距離・右条件, NC LH : 腰高・近距離・中央条件,
- NL LH : 腰高・近距離・左条件, NR LH : 腰高・遠距離・右条件,
- NC LH : 腰高・遠距離・中央条件, NL LH : 腰高・遠距離・左条件

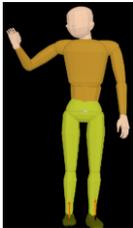
2.5 考察

2.5.1 作業条件と姿勢による比較

表 2.5.1 に肩高条件の作業姿勢, 作業のしにくさ, 作業姿勢を目視して判定した RULA[21] による評価値, 異常率の関係を示す. 近距離・左条件の RULA のスコアは, 特に上腕および体幹部のスコアが他の条件と比較して大きかった. 近距離・左条件は他の近距離条件の結果と異なり, 体幹部を左旋させ, その角度も大きい. また, 図 2.4.4 の右肩関節外転角と図 2.4.5 の右肩関節屈曲角の結果は他の近距離の結果と異なり, 右肩関節が内転し, 肩関節を大きく屈曲する傾向が見られた. RULA の結果は, これらの関節角度の変化の影響を反映し, スコアが加算されている. また, 近距離・左条件の作業は, 左にある作業対象物に対して右手でリーチを行うため, 体の正中線を横切るような姿勢を形成する. RULA による評価では, このような作業姿勢は前腕のスコアが加算される. したがって, 近距離・左条件は, RULA の総合スコアも大きく, AL の判定も 3 (速やかな調査と変更が必要) となっている. また, 近距離・左条件における図 2.4.5 の右肩関節屈曲角の結果は他の近距離の結果と比較して大きく屈曲する傾向にあった. 全身の関節が中立位にない場面の主観的な不快の程度を基準に作成されたチェックリストである LUBA[140]による評価では, 肩の屈曲角が増加するのに伴い負担感や不快感が増加するため, 他の距離の作業姿勢と比較して近距離・左条件は被験者にとって負担感や不快感の高い作業である. 実際に, 近距離・左条件の主観的な作業のしにくさは高く, **One-Class Support Vector Machine** の結果においても, 上肢の異常率, 総合異常率ともに最も高くなった. これらの結果から, **One-Class Support Vector Machine** による評価は, RULA や LUBA などの従来の人間工学評価手法による評価結果と同様の傾向を示すことから, 作業姿勢の問題点の検出のために有用である可能性が示唆された.

近距離・中央条件の RULA のスコアは, 近距離・左条件と比較して上腕と体幹部のスコアが小さかった. 上腕および体幹部のスコアは, 近距離・左条件と比較して, 図 2.4.5 の肩関節屈曲角が小さいこと, 体幹部が右旋し, その大きさも小さいことから妥当なスコアである. 近距離・中央条件の前腕のスコアは近距離・左条件と同じ値であった. これは, RULA による評価では, 近距離・中央条件のような体の横に前腕が出ている作業姿勢は, 前腕のスコアが加算されるためである. RULA による総合スコアは 3 であり, AL の判定も近距離・左条件以外の全ての条件と同じ 2 (さらなる調査が必要で, 変更が望まれる) であり, 負担の小さい作業条件であったと判定されている. しかし, 近距離・中央条件は, 近距離・左条件と同程度の作業のしにくさを記録している. **One-Class Support Vector Machine** の結果は, 上肢の異常率, 総合異常率ともに 2 番目に大きな値となっており, 作業がしにくい条件において異常率が増加する傾向を示した. これらの結果から, **One-Class Support Vector Machine** による評価は, RULA などの観察法では判定が難しいようなわずかな作業姿勢の差を検出し, 作業姿勢の問題点の検出が可能であることが示された.

表 2.5.1 肩高条件の作業姿勢，作業のしにくさ，RULA 評価値，異常率の関係

						
実験条件	左	中央	右	左	中央	右
	近距離			遠距離		
作業のしにくさ	大	大	中	中	小	小
RULA 上腕スコア	4	2	2	3	3	2
RULA 前腕スコア	3	3	3	2	2	2
RULA 手首スコア	2	3	3	3	4	3
RULA 頸部スコア	4	3	3	2	3	2
RULA 体幹スコア	3	2	2	3	1	2
RULA 総合スコア	6	3	3	4	4	3
RULA AL 判定	3	2	2	2	2	2
上肢の異常率 ($\nu = 0.10$)	5%	3%	1%	3%	2%	2%
総合異常率 ($\nu = 0.10$)	10%	6%	2%	4%	3%	4%

2.5.2 部位ごとの検出回数の比較

作業高さが高くなるのに伴い，右上肢の異常率が増加する傾向が示された．図 2.4.4 から図 2.4.6 および図 2.4.8 の関節角度，関節トルク比は作業高さが高くなるのに伴い増加し，異常率と同様の傾向が示された．RULA や LUBA などの評価では上腕を挙上する姿勢や肩関節を大きく屈曲する姿勢が負担感の高い姿勢と判定される．本研究で得られた結果は，作業高さにより右上肢に関連する関節角度が増加し，負担感，不快感が増加する姿勢を取って

いた。これらの結果から部位ごとに提案手法を適用することにより、RULA や LUBA など
で負担感や不快感が高いと判定される作業を異常姿勢として抽出することが可能であると
考えられる。

2.5.3 外れ値の条件の妥当性の検証

本研究における ν の値は0.01, 0.05, 0.10の3種類を設定した。これは統計的有意水準(90%,
95%)ならびに Mahadeva and Shah [141]の研究で用いられた信頼水準(99%)から設定した。
図 2.4.10 の結果から、 $\nu = 0.10$ の時、近距離・左条件と近距離・中央条件の異常率が増加し
た。図 2.4.9 の作業のしにくさの結果は近距離・左条件と近距離・中央条件において増加し
ているため、異常率との関係が見られる。2.5.1 で述べたように、提案手法によって、従来
の姿勢計測の結果を用いる評価方法では数値的な表現が困難であった作業のしにくさを、
異常率の増加という観点から示すことができたと考えられる。

図 2.4.12 の ν を変化させたときの異常率の推移を確認した。 ν の値域は、Li の研究[142]に
おいて 0.01~0.25 の範囲で ν の値を変化させていたことを参考にして設定した。図 2.4.12 の
結果から、異常率は $\nu = 0.05$ から変化し始め、 $\nu = 0.10$ 以降では傾向に変化はなかった。こ
れらの結果から、本研究において設定した外れ値の妥当性を示すことができたと考えられ
る。

2.6 小括

本研究では、One-Class Support Vector Machine を用いて、作業中における異常姿勢の検出
方法を提案し、関節角度や関節トルク比、主観評価などの従来の評価指標と異常率の関係か
ら One-Class Support Vector Machine が作業性評価に有用か実験的に検証した。本研究により
得た以下の知見より、One-Class Support Vector Machine を作業性の評価に活用できることを
確認した。

- 1) 近距離・左条件は最も作業がしにくい条件であり、One-Class Support Vector Machine の
異常率は増加する。この傾向は RULA や LUBA による評価と関係が見られる。
- 2) 近距離・中央条件は近距離・左条件に次いで作業がしにくい条件であり、全てのクォー
タニオンを特徴ベクトルとした時の One-Class Support Vector Machine の結果、異常率が
増加する。一方で、近距離・中央条件の関節角度や関節トルク比の傾向は、作業がしや
すい条件と近い傾向にある。
- 3) 各部位ごとに One-Class Support Vector Machine を適用した時の右上肢の異常率は、作業
高さが高くなるのに伴い増加する。この傾向は RULA や LUBA による評価と関係が見
られる。
- 4) ハイパーパラメータ ν が 0.10 以降では、各条件間の傾向が大きく変化しない。先行研究
による ν の設定範囲内であり、パラメータ設定の妥当性を示した。

第3章 静止姿勢を対象とした異常検知手法を用いた作業姿勢評価： 障害物回避を伴うリーチ作業を対象とした One-Class Support Vector Machine の有用性の検証

3.1 緒論

静止姿勢を対象とした異常検知手法を用いた作業姿勢評価として、第2章では作業域が制限されているため関節角度の変化が小さく、従来までの関節角度や関節トルク比の評価では差を明らかにすることは難しいが、作業性の主観評価には影響が出やすい身体近傍での低負荷作業として、身体近傍でのねじ締め作業への適用例について述べた。近年、多くの作業は自動化されることから第2章で実施したような低負荷作業が主流である。しかし、保守点検作業など非定型で十分な作業空間も確保できない作業は、依然として人間の手作業で行われている。たとえば航空機のメンテナンスにおいては、体幹部のひねりを伴う作業や長時間の頭上での作業などの不自然な作業姿勢をとることが筋骨格系障害発症のリスク要因となることが報告されている[143]。また、保守点検作業では移動できない障害物を回避しながら、作業を行う場面も見られる。Vaughan et al.[144]は目標地点までのリーチ軌道に障害物がある場合、障害物との接触を避けるために新たな経路点を生み出し、軌道が変化するモデルを提案している。したがって、障害物回避によって作業姿勢が変化し、過度な身体負担の増加を引き起こす可能性がある。そのため、作業者にとって快適な作業姿勢を取ることが可能な条件を選択すること、あるいは特に負荷の高い作業工程を改善することは、作業者の快適性の向上のために重要である。そこで、第2章と同様に静止姿勢を対象とした異常検知手法である One-Class Support Vector Machine を用いた作業姿勢評価を試みる。

本章では、保守作業を模した障害物回避を伴うリーチ作業を対象に One-Class Support Vector Machine の有用性を明らかにすることを目的とする。具体的には、作業高さ3水準、障害物高さ2水準、障害物幅2水準を組み合わせた実験を行い、従来の人間工学評価として関節角度、作業の困難さについて測定し、One-Class Support Vector Machine による姿勢分類結果と比較した。従来の人間工学評価との比較に基づき、One-Class Support Vector Machine による姿勢分類結果の妥当性および有用性を評価する。

3.2 実験方法

3.2.1 被験者

被験者は右利きの男子学生 11 名であった。被験者の年齢、身長、体重の平均±標準偏差は、22.6±0.8 歳、1705±84mm、66.5±11.0 kg であった。また、上肢長、肘高、肩峰高、左右肩峰幅の平均±標準偏差は、744±44 mm、1054±68 mm、1398±86 mm、369±31 mm であった。なお、本実験は首都大学東京日野キャンパスの研究安全倫理委員会の承認を得て実施した。実験を始める前に被験者に実験の概要を説明して書面による同意を得た。

3.2.2 実験条件

実験条件は図 3.2.1 に示す作業高さ、障害物高さ、障害物幅を組み合わせて設定した。作業高さ条件は全 3 水準（低い、普通、高い）とし、被験者の肘高の 80%、100%、120%にそれぞれ設定された。障害物高さ条件は全 2 水準（低い、高い）とし、低い障害物高さ条件は被験者の肩峰高に、高い障害物高さ条件は被験者の身長にそれぞれ設定された。障害物幅条件は全 2 水準（狭い、広い）とし、被験者の左右肩峰幅の 25%と 50%に設定された。さらに、被験者は障害物ない状態で、各高さ条件のリーチタスクを実施した。

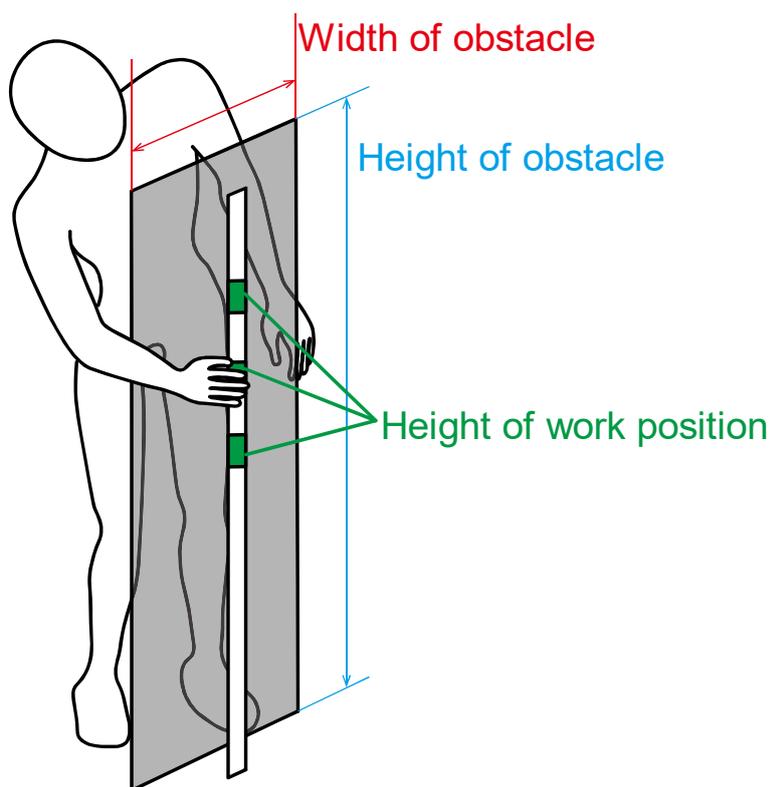


図 3.2.1 実験条件

3.2.3 実験手順

被験者は、障害物を避けながら、事前に定義された目標位置へ手を伸ばすリーチ作業を実施した。実験開始時に、被験者は T ポーズ（立ったまま両腕を広げた状態）を 5 秒間保持した。その後、被験者は指示された作業位置へリーチする作業姿勢を形成し、その姿勢を 5 秒間保持した。その後、被験者は待機姿勢に戻った。この一連の流れを同一の条件下で 3 回繰り返した。被験者は、障害物の上部または右側から目標位置を視認し、右手で目標位置へリーチするように指示された。

3.2.4 計測項目および解析方法

3.2.4.1 作業姿勢

光学式モーションキャプチャシステム (OptiTrack, NaturalPoint 社製) を用いて, 被験者の体表面に設置されたマーカの 3 次元位置を計測した. 続いて, 光学式モーションキャプチャソフトウェア (ARENA, NaturalPoint 社製) を使用して, 各身体セグメントの位置を推定した. 被験者の身体サイズと各マーカ位置の関係は, BVH ファイルとして出力された. 関節角度は, BVH ファイルを 3 次元剛体リンクモデルにあてはめることによって計算した. 各試行の平均作業姿勢データは, 5 秒間リーチ姿勢を保持したデータの平均として定義された. 各実験条件について, 平均関節角度は, 33 個の平均作業姿勢データ (11 人×3 試行) から計算された.

3.2.4.2 主観評価

被験者は障害物回避タスクと姿勢維持の困難さ (作業の困難さ) を 1 (非常に簡単) から 5 (非常に困難) の 5 段階で評価した.

3.2.4.3 異常率の計算

第 2 章で提案した One-Class Support Vector Machine を用いた作業姿勢の分類手順を利用し, 障害物回避タスク中の作業姿勢の異常の検出を試みる.

測定ミスがあった 1 つのデータを除いた 395 データ (被験者 11 名×作業高さ 3 水準×障害物幅条件 2 水準×障害物高さ条件 2 水準×3 試行-1) を One-Class Support Vector Machine へ適用した. ハイパーパラメータ ν は標準的な統計的有意水準の値を参考に, 0.05 に設定された. 本章では, One-Class Support Vector Machine の有用性を検討するために, 異常率と主観評価の結果を比較した.

3.3 結果

3.3.1 関節角度

図 3.3.1 は各実験条件の体幹右傾角の平均値を示している。障害物の幅が増加するのに伴い、体幹右傾角が増加した。作業高さ条件が普通および高い場合、障害物高さが高い条件における体幹右傾角の方が障害物高さが低い条件よりも大きかった。

図 3.3.2 は各実験条件の頸部右屈角の平均値を示している、頸部右屈角はほとんど全ての条件において、障害物幅の増加に伴い増加した。

図 3.3.3 は各実験条件の右肩関節外転角の平均値を示している。作業高さが普通および高い場合、障害物高さが低い条件において、障害物幅に応じて右肩関節外転角が増加した。障害物高さが高い場合、右肩関節外転角は中立位でほぼ一定のままであり、作業高さが高い場合、障害物幅とともにわずかに増加した。作業位置が低い場合、障害物幅が狭い条件で右肩関節外転角が増加した。

3.3.2 主観評価

図 3.3.4 は各実験条件における作業の困難さを示している。全体的に、障害物幅の増加に伴い、作業の困難さが増加した。しかし、作業高さ条件が高くなるのに伴い、作業の困難さは低下した。

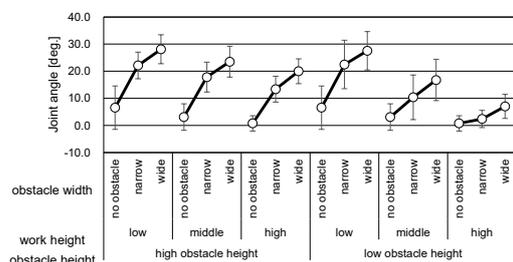


図 3.3.1 体幹右傾角

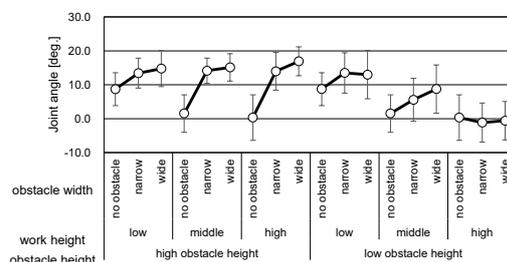


図 3.3.2 頸部右屈角

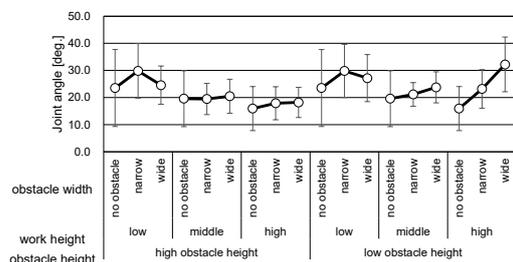


図 3.3.3 右肩関節外転角

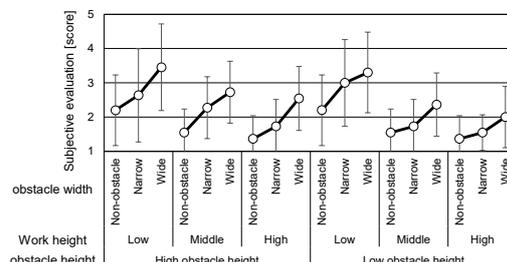


図 3.3.4 作業の困難さ

3.3.3 姿勢の異常率

図 3.3.5 は各実験条件での各身体セグメントの異常率とそれらの合計値を示している。作業高さ条件が高い場合および障害物高さ条件が低い場合を除いて、障害物幅の増加に伴い異常率の合計が増加した。ほとんどの実験条件において、体幹部の異常率は減少するか、一定のままであった。対照的に多くの実験条件において、障害物幅が増加するのに伴い、右上肢および頭頸部の異常率が増加した。

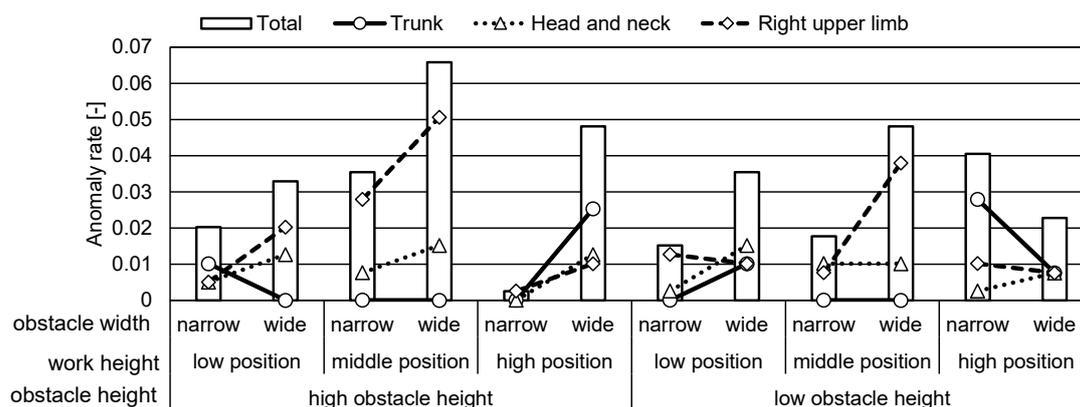


図 3.3.5 各実験条件での各身体セグメントの異常率とそれらの合計値

3.4 考察

本研究では、One-Class Support Vector Machine を使用して障害物回避タスク中の作業姿勢の異常を検出した。本研究の実験結果は、作業高さが高い条件と障害物高さが高い条件を除いて、ほとんどの実験条件で障害物幅の増加に伴い作業姿勢の異常率の合計値が増加することを示した。また、作業の困難さも障害物幅とともに増加した。

表 3.4.1 に作業高さが低く、障害物高さが高い条件における作業姿勢、作業の困難さ、作業姿勢を目視して判定した RULA[21]評価値、異常率の関係を示す。障害物幅が狭い条件と広い条件の RULA による評価結果を比較すると、頸部のスコア以外に差が見られなかった。RULA による評価において、頸部が後屈する場合、RULA スコアは、角度によって定められるスコアの中では最大である 4 となる。さらに、頸部が側屈または回旋している場合、それぞれにつき 1 ずつスコアが加算される。障害物幅が広い条件では、頸部が後屈し、さらに側屈や回旋によるスコアが加算されることによって、頸部の取りうる最大スコアを記録した。これらの結果は、障害物幅の増加に伴い、覗き込み姿勢に変化が生じ、頸部への負荷を増加させたことを示している。One-Class Support Vector Machine による頸部の異常率は、障害物幅の増加に伴い増加し、RULA による評価と同様の傾向を示した。このことから、One-Class Support Vector Machine は、RULA などの従来の人間工学評価法で検出可能な問題点を検出できることを示し、作業姿勢の問題点の検出へ有用であることが示唆された。

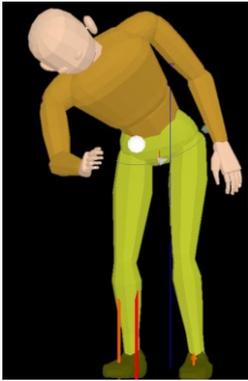
上肢や体幹部の RULA の評価結果において障害物条件による差は見られなかった。一方

で、One-Class Support Vector Machine による評価結果によれば、体幹部の異常率は減少し、右上肢の異常率が障害物幅とともに増加した。体幹部の異常率の結果は、体幹部を右へ傾ける条件が作業姿勢の主要なパターンとなってしまったため、データの学習に偏りが生まれ、正しく作業姿勢の問題点が検出されなかった可能性がある。右上肢の異常率は障害物幅の増加に伴い増加したが、RULA による上腕および前腕のスコアに変化はなかった。これは、RULA による評価では、肩関節が外転していれば、角度に関わらずスコアが1加算されるために、わずかな姿勢の違いを検出することが困難であったことが原因だと考えられる。図 3.3.3 に示されている作業高さが低く、障害物高さが高い条件における肩関節外転角の平均値は、障害物幅が狭い条件の方が大きかった。一般的には、肩関節外転角が大きい方が肩関節に発生するトルクが増加するため姿勢保持が困難になる。したがって、肩関節外転角が大きい作業姿勢の方が身体負担の観点から見ると問題のある作業姿勢であるといえる。本研究では、体幹部の変化が関連し、肩関節外転角の小さい条件の異常率が増加したと推察される。障害物幅の増加に伴い、体幹部右傾角が大きく変化するため、被験者は肩関節外転角を必要以上に大きく変化させずに、目標位置へリーチが可能になったと考えられる。そのため、肩関節外転角を主に変化させてリーチ姿勢を形成した他の条件と異なる傾向を取ったと判断され、異常率が増加したと推察される。この結果から、One-Class Support Vector Machine では体幹部の変化のような主要な作業姿勢パターンの異常検知は難しいが、主要な変化に伴い発生する肩関節外転角の姿勢変化などのわずかな姿勢の変化をとらえることができる可能性がある。また、作業高さが低く、障害物高さが高い条件を除いた条件においては、右上肢と頭頸部の異常率が障害物幅とともに増加した。図 3.3.3 に示される右肩関節外転角の結果は、障害物幅の増加に伴い、右肩関節外転角が増加することを示している。肩関節外転角の傾向は、RULA および REBA[19]などでスコアが加算される作業姿勢であるが、特に RULA の場合、肩関節外転角の大きさの違いは考慮されない。One-Class Support Vector Machine による評価結果は、右肩関節外転角のわずかな差を考慮し、主観的な作業の困難さとの関係を示したことから、右上肢や頭頸部の異常姿勢を特定できる可能性を示唆している。

本研究では、障害物幅が増加しても、体幹の作業姿勢の異常率は増加しなかった。ただし、体幹右傾角は障害物幅の増加に伴い増加した。体幹右傾角が増加すると、腰部関節トルク比と L5/S1 椎間板圧縮力などの身体負担が増加する。産業現場での身体負担を軽減するために、まず身体負担を増加させるような作業姿勢を検出して、そのような作業姿勢を取らないような作業環境を設計する必要がある。しかし本研究では、One-Class Support Vector Machine を用いて身体負担が増加した作業姿勢を特定することができなかった。One-Class Support Vector Machine が障害物がある条件のみに適用されたため、ほとんどの観測データは体幹右傾角を変化させた姿勢となり、体幹右傾角が変化することによって腰部の身体負担が増加する可能性がある。つまり、高い身体負担である作業姿勢が観測データにおいて主要な傾向である場合、One-Class Support Vector Machine では身体負担が高い作業姿勢を異常と判断す

ることは困難である．身体負担を考慮した重みづけ One-Class Support Vector Machine[145][146]を使用した作業姿勢の分類方法がこれらの問題の解決に役立つ可能性がある．

表 3.4.1 作業高さ 低・障害物高さ 高条件の作業姿勢・RULA 評価値・異常率の関係

		
障害物幅	狭い	広い
作業の困難さ (障害物幅条件間での比較)	低	高
RULA 上腕スコア	5	5
RULA 前腕スコア	3	3
RULA 手首スコア	3	3
RULA 頸部スコア	5	6
RULA 体幹スコア	5	5
RULA 総合スコア	7	7
RULA AL 判定	4	4
体幹の異常率	1.0%	0%
頸部の異常率	0.5%	1.3%
上肢の異常率	0.5%	2%
総合異常率	2.0%	3.3%

3.5 小括

本研究は障害物回避を伴うタスク中の作業姿勢の評価へ One-Class Support Vector Machine を適用し、その有用性を従来の人間工学評価との関係から評価した．ほとんど全ての実験条件で、障害物幅の増加に伴い、右上肢と頭頸部の異常率が増加した．障害物幅の増加により、作業の困難さが増加したことから、作業の困難さが右上肢や頭頸部の影響を受けていることが示唆された．これらの結果は保守点検作業などで障害物を回避する際に生じる右上肢や頸部の作業姿勢の変化を検出し、作業性が低下する条件を特定できることを示唆している．

第4章 時系列データを対象とした異常検知手法を用いた作業動作評価： 特異スペクトル変換を用いた突発的な作業姿勢の変化の検出

4.1 緒論

第2章および第3章では、静止姿勢を対象とした作業姿勢評価への異常検知手法の有用性を検証した。これらの平均値や中央値もしくは任意の時刻の作業姿勢をサンプリングなど代表値となる静止姿勢を用いた評価のみでは、反復作業など同様の作業を繰り返し実施する中で発生するごくわずかな作業姿勢の変化や、作業動作のばらつきなどの作業姿勢の緩やかな変化を見落とす可能性がある。突発的に生じる作業姿勢の変化として、作業ミスの発生や危険事象に対する回避行動の発生などが挙げられる。これらの突発的な作業姿勢および動作の変化を検出することは、生産性や安全性の向上に寄与することが可能であると考えられる。また、作業姿勢の緩やかな変化などは、低負荷作業であっても繰り返し作業を実施することによる筋疲労の発生など、作業者の快適性の向上のために考慮すべき要因である。そこで本章以降では、時系列データを対象とした異常検知手法を用いた作業姿勢評価を試みる。

特異スペクトル変換は、時系列データにおける作業姿勢の問題を検出するのに有用な手法の1つである[107]。特異スペクトル変換や類似手法である特異スペクトル解析[108]は、旋削プロセスにおける振動成分の信号処理[113]、工具摩耗のモニタリングにおけるノイズ除去[114]などの機械の稼働監視や工具状態のモニタリングに応用されている。さらに人間工学および生理学分野における先行研究では、特異スペクトル変換および特異スペクトル解析は脳波および心電図からのノイズ除去[116][117]、歩行パラメータの推定[118]、筋電図の開始点の検出[119]に応用されている。しかし、作業ミスや作業ペースに関連する突発的な作業姿勢の変化の検出への応用を行った研究は少なく、特異スペクトル変換のパラメータの調整や突発的な姿勢変化の検出に対する有用性の検討などを行う必要がある。

本章では、突発的な作業姿勢の変化の検出に異常検知手法を応用することを試みる。具体的には、作業間隔を突発的に変化させた軽量物の取り置き作業中の作業姿勢の時系列データに対して特異スペクトル変換を適用し、作業姿勢変化の検出に対する有用性を明らかにすることを目的とする。特異スペクトル変換による作業姿勢変化の検出のために、作業中の時系列における姿勢の変化を検出するためのしきい値を提案し、特異スペクトル変換の重要なパラメータの1つであるラグに着目して、ラグの変更が異常スコアに与える影響を明らかにする。

4.2 理論

4.2.1 特異スペクトル変換の概要

特異スペクトル変換は変化点スコアや異常スコアに基づいて元の時系列データを新しい時系列データへ変換するアルゴリズムである[107]. 特異スペクトル変換は, 類似手法である特異スペクトル解析に基づいている. ある時系列 $\mathcal{T} = \{x(1), x(2), \dots, x(t), \dots, x(N)\}$ と窓幅 M を用いた連続した部分時系列 $\{x(t-M), \dots, x(t-2), x(t-1)\}$ を考える. この時, 連続した部分時系列をベクトルとして以下のように定義する.

$$\mathbf{s}(t-1) = (x(t-M), \dots, x(t-1))^T, \quad (4.1)$$

ここで上付き文字 T は転置を示す. ハンケル行列として定義される行列 $\mathbf{X}(t)$ を上記の列ベクトルを用いて以下のように構成する.

$$\mathbf{X}(t) \equiv [\mathbf{s}(t-n), \dots, \mathbf{s}(t-2), \mathbf{s}(t-1)]. \quad (4.2)$$

この $M \times n$ 行列を時刻 t における履歴行列と呼ぶ. 定義から, 履歴行列は $x(t-1)$ から $x(t-M-n+1)$ までの $M+n-1$ 個の要素で構成される.

履歴行列よりも未来の時刻において, 窓幅 M を用いた連続した部分時系列 $\mathbf{w}(t+L)$ は以下のように定義される.

$$\mathbf{w}(t-1) = (x(t+L), \dots, x(t+L+M-1))^T. \quad (4.3)$$

これは $\mathbf{s}(t+L+M-1)$ と同義であるが, 時刻 t における対称性を示すために新しい定義として導入する. 上記の列ベクトルを用いて時刻 t におけるハンケル行列を以下のように構成する.

$$\mathbf{Z}(t) \equiv [\mathbf{w}(t+L), \mathbf{w}(t+L+1), \dots, \mathbf{w}(t+L+k-1)]. \quad (4.4)$$

この $M \times k$ 行列を時刻 t におけるテスト行列と呼ぶ. L はラグと呼ばれる履歴行列とテスト行列の相互位置を決める非負定数である.

変化点スコアまたは異常スコアは2つの主部分空間の差として定義される. 時刻 t における履歴行列とテスト行列の主部分空間 $\mathbf{U}_r(t)$ および $\mathbf{Q}_m(t)$ はそれぞれ以下のように定義される.

$$\mathbf{U}_r(t) \equiv [\mathbf{u}_1(t), \mathbf{u}_2(t), \dots, \mathbf{u}_r(t)], \quad (4.5)$$

$$\mathbf{Q}_m(t) \equiv [\mathbf{q}_1(t), \mathbf{q}_2(t), \dots, \mathbf{q}_m(t)]. \quad (4.6)$$

ここで、 $\mathbf{u}_r(t)$ および $\mathbf{q}_m(t)$ は履歴行列 $\mathbf{X}(t)$ とテスト行列 $\mathbf{Z}(t)$ を特異値分解して得られる左特異ベクトルである。 r および m は特異値分解をして得られる左特異ベクトルの本数を示す。時刻 t における異常スコア $a(t)$ は以下の式で計算される。

$$a(t) = 1 - \|\mathbf{U}_r(t)^T \mathbf{Q}_m(t)\|_2. \quad (4.7)$$

定義より、異常スコア $a(t)$ は0から1の範囲の値をとる。異常スコアが小さい時、過去のパターンと比較して変化は小さく、異常スコアが大きい時、現在の時刻の動作は過去のパターンと異なることを示す。

4.2.2 パラメータ選択

特異スペクトル変換には以下の表 4.2.1 に示す 6 つのパラメータが存在する。

表 4.2.1 特異スペクトル変換におけるパラメータと異常スコアに与える影響

パラメータ	異常スコア・変化点スコアに与える影響
M 部分時系列の長さ	<ul style="list-style-type: none"> ・ 大きいほど異常スコアのグラフが滑らかになり、異常に対する感度が低下する ・ 短すぎると周期の長い正常な変化と異常値を区別することができなくなる
L ラグ	<ul style="list-style-type: none"> ・ ラグが短すぎると時間をかけて緩やかに変化するタイプの異常を検出しづらくなる ・ ラグが長すぎると異常の発見が遅れる ・ 周期性がある場合、周期の倍数をラグにすると、周期的な変動を打ち消すことができる
n 履歴行列の列数	<ul style="list-style-type: none"> ・ 部分時系列の長さMと合わせて、過去のデータのどこまでを異常スコアの計算に用いるか決定する
k テスト行列の列数	<ul style="list-style-type: none"> ・ 部分時系列の長さMと合わせて、過去のデータと比較する現在のデータパターンを決定する
r 履歴行列側の主部分空間の列数	<ul style="list-style-type: none"> ・ 履歴行列を特異値分解して得られる左特異行列から取り出す左特異ベクトルの数を決定する ・ 取り出す特徴量の選択と同義
m テスト行列側の主部分空間の列数	<ul style="list-style-type: none"> ・ テスト行列を特異値分解して得られる左特異行列から取り出す左特異ベクトルの数を決定する ・ 取り出す特徴量の選択と同義

ほとんどのパラメータは経験的に決定する必要があるが、一部のパラメータ、特に部分時系列の長さ M についてはいくつかの先行研究でその決定方法について議論されている。Kuigumtzis[147]は信号のピーク間の平均時間と一致する必要があると提案し、Kim et al.[148]は C-C method (a correlation integral-based method)を用いた時間遅れと部分時系列の長さの計算方法を提案している。また、Hassani et al.[149]は部分時系列の長さは信号の周期に比例する必要があることを報告している。しかし、依然として他のパラメータに関しては経験的に検討する必要がある。反復作業における人間の作業姿勢・動作の異常を検出するためには、前の作業区間と現在の作業区間が同一の作業である必要があり、ラグ L の選択が重要になることが予想される。そこで、本章で実施した研究ではラグ L に着目し、ラグ L を変更した時の異常スコアに与える効果について検討する。

4.3 実験方法

4.3.1 被験者

被験者は 11 名の右利きの男性であった。被験者の年齢、身長、体重の平均±標準偏差は、 23.1 ± 1.5 歳、 1732 ± 42 mm、 67.4 ± 9.0 kg であった。また、被験者の手長、前腕長、上肢長は 185 ± 11 mm、 441 ± 17 mm、 740 ± 27 mm であった。なお、本実験は首都大学東京日野キャンパスの研究安全倫理委員会の承認を得て実施した。実験を始める前に被験者に実験の概要を説明し書面による同意を得た。

4.3.2 実験条件

実験は被験者が座位姿勢で 50 個の球状の軽量物（直径=35 mm、重さ=8 g）を事前に指示された作業間隔で所定の位置へ移動させる作業を実施した。被験者は図 4.3.1 に示す 2 種類のタスクを実施した。タスク A において被験者は、被験者から見て左側のカゴから右側のカゴへ軽量物を移動させた。左側と右側のカゴの中心間距離は 400 mm に設定した。タスク B において被験者は、被験者から見て奥のカゴから手前のカゴへ軽量物を移動させた。奥および手前のカゴの位置は測定装置の端点からそれぞれ 1100 mm、800 mm に設定された。また被験者が軽量物を取りやすくするために、奥のカゴを 10° 傾けた。実験では、突発的な姿勢変化を誘発するために、作業間隔条件を変更した。作業間隔条件は一定とランダムとの 2 水準とした。基本的なタスク間隔は両条件とも 3 秒とし、ランダム条件においては、全試行回数の 20%のみ作業間隔を 1.5 秒に変更した。作業間隔の減少のタイミングは乱数を用いて完全にランダムで実施した。被験者はタスク A および B をランダムな順序で実施し、それぞれのタスクの間には十分な休憩を設けた。ランダム条件は被験者が作業に慣れた状態で実施する必要があったため、作業間隔条件は必ず一定条件から実施し、その後続けてランダム条件を実施した。

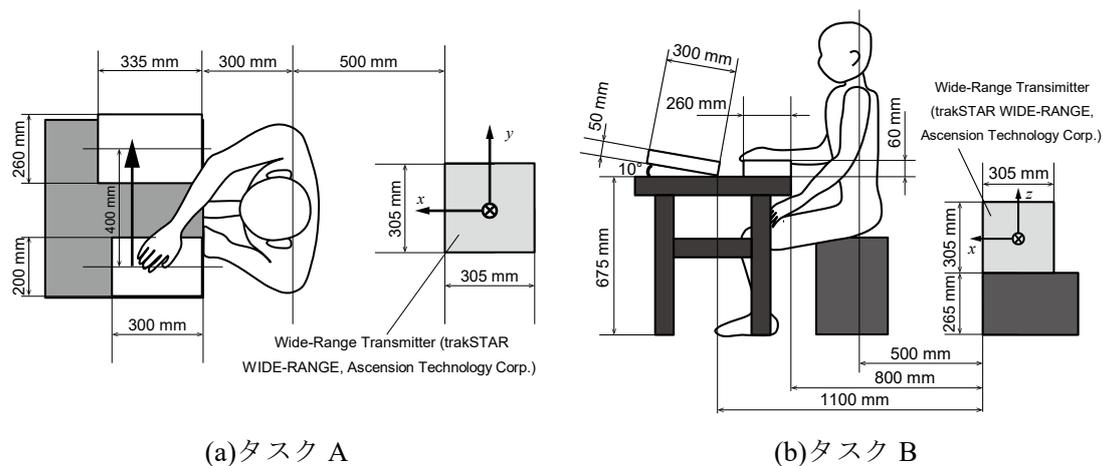


図 4.3.1 タスク条件

4.3.3 実験手順

被験者は座位姿勢で解剖学的基本姿勢を保持した状態で実験を開始した。その後、被験者は腕を下垂した自然な姿勢（以下、自然姿勢）を 5 秒間保持した。被験者はメトロノームの音が鳴るまで自然な姿勢で待機し、メトロノームの音が鳴った後、メトロノームの音に合わせて事前に指示されたカゴへ軽量物を移動させた。軽量物を 1 つ移動させる度に、被験者は自然姿勢へ戻るよう指示された。ただしランダム条件の場合、被験者が自然姿勢に戻る前にメトロノームの音が鳴った場合、被験者は自然な姿勢に戻ることなく、軽量物の移動を優先させた。全ての軽量物の移動後、被験者は解剖学的基本姿勢を 5 秒間保持し、実験を終了した。

4.3.4 測定項目と解析方法

4.3.4.1 作業姿勢

磁気式 3 次元位置測定装置 (trakSTAR, Ascension Technology Corp.) を用いて腰部、胸部、右上腕、右前腕、右手根の 3 次元位置と方位を測定した。trakSTAR の Wide-Range Transmitter の座標系に対する各身体セグメントの相対位置と方位を約 60 Hz のサンプリング周波数で記録した。trakSTAR のレーザーを腰部、胸部、右上腕、右前腕、右手首に設置した。レーザーの位置は、先行研究[150]によって報告されている皮膚の変化によるセンサのずれを避ける位置に設置した。

右上肢の関節角度は 3 次元剛体リンクモデルに測定した各身体セグメントの方位を適用して計算し、肘関節屈曲/伸展角、前腕回内/回外角、手関節撓屈/尺屈角、手関節掌屈/背屈角について導出した。各実験条件下でタスク条件ごとに計算された関節角度の最大値と最小値を記録した。ただし、作業開始時の解剖学的基本姿勢および自然姿勢を保持した時間は計算から除外した。先行研究[151]を参考に、各実験条件の実可動域 (actual range of motion) を関節角度の最大値と最小値の差として定義した。その後、実験条件ごとに被験者間の最大値、

最小値, 実可動域の平均および標準偏差を計算した. 実験中の関節角度の変化度合いを比較するために, 実可動域の標準偏差を参考可動域 (reference range of motion) [152]で除した比率 η を動作のばらつきの指標として以下の式で定義した.

$$\eta = \frac{act\sigma_{ROM}}{refROM_1 + refROM_2} \quad (4.8)$$

ここで, $act\sigma_{ROM}$ は実可動域の標準偏差, $refROM_1$ および $refROM_2$ は中村ら[152]によって報告された, 肘関節屈曲/伸展, 前腕回内/回外, 手関節撓屈/尺屈, 手関節掌屈/背屈角の参考可動域を示す. 例えば肘関節屈曲角の場合は, $refROM_1$ および $refROM_2$ はそれぞれ屈曲方向および伸展方向の参考可動域を示す. 他の関節角度についても同様である.

4.3.4.2 特異スペクトル変換を用いた異常スコアの計算

各関節角度の時系列データに特異スペクトル変換を適用し, 異常スコアを計算した. 特異スペクトル変換のパラメータはそれぞれ, $M = 50$, $L = 150$, $n, k = M/2$, $r, m = 3$ であった. M , n , および k は観測された1タスク当たりの時間が約1.5秒であったことに従い, おおよそそのタスク周期に一致するように定義した. ラグ L の値は基本的なタスク間隔(3秒)を反映している. 各実験条件間の比較を行うために, タスク全体の異常スコアの平均および変動係数を計算した.

計算された異常スコアは関節角度の異常の程度を示し, 現在の試行で観察された関節角度を過去の試行と比較することによって決定される. ただし, 人間の動作の問題を判定するためのしきい値が定義されていない. そこで本研究では, X-R管理図の考え方を参考にしきい値を $\mu + 3\sigma$ と設定した[153]. μ と σ は各実験条件における各関節角度の異常スコアの平均と標準偏差を示す.

ラグ L の影響を L を50から250まで20ずつ変化させたときの異常スコアの値から検証した. 参加者が解剖学的基本姿勢および自然姿勢を保持した時間を除いて, 異常スコアを最小にする L の値を記録した. 各 L の選択数の合計値に対する相対値として, ラグ L の採択率を定義し, 各実験条件間で比較した.

4.3.4.3 統計解析

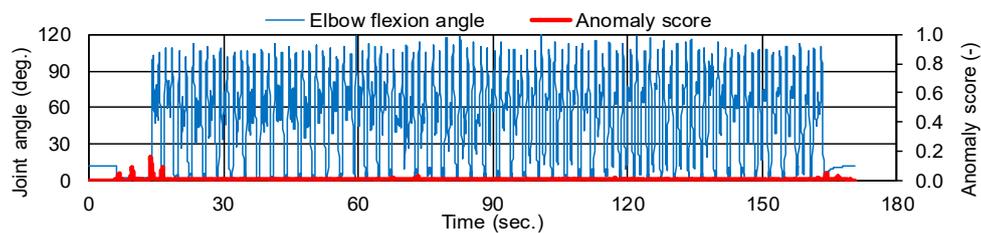
統計解析には多元配置分散分析を使用した. 実験要因はタスクの種類およびタスク間隔条件とし, 被験者はブロック因子として統計解析に含めた. 統計的有意水準は5%とした.

4.4 結果

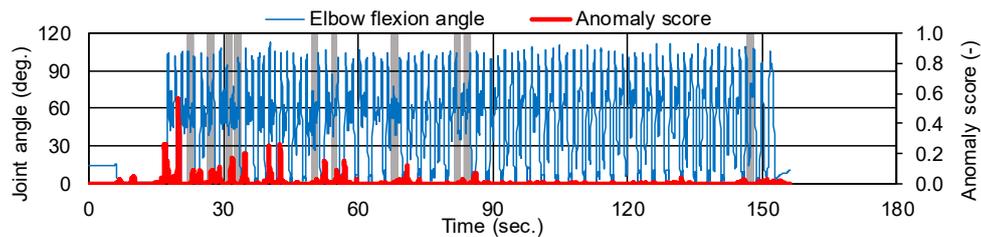
4.4.1 被験者 1 名の関節角度と異常スコアの時間変化の一例

図 4.1.1 に被験者 1 名分のタスク A の異常スコアと肘関節屈曲角の経時変化を示す。タスク間隔が減少した時刻はグレーで塗りつぶされている。一定条件の場合、異常スコアは被験者が解剖学的基本姿勢から自然姿勢へ変化する実験の初期段階で増加した。異常スコアは一定条件よりもランダム条件の方が頻繁に増加した。

図 4.4.2 に被験者 1 名分のランダム条件の異常スコアと手関節掌屈角の経時変化を示す。手関節撓屈角および異常スコアの最大値はタスク B よりもタスク A の方が大きかった。

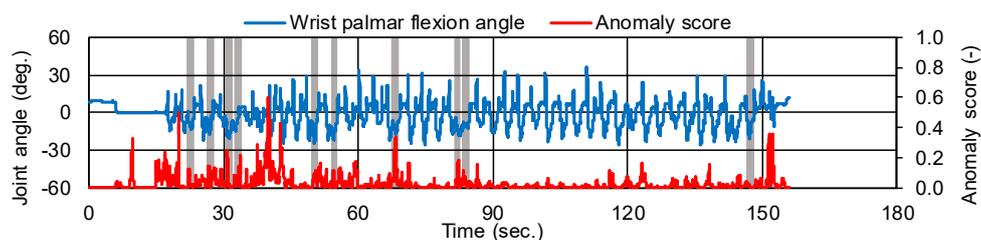


(a)一定間隔

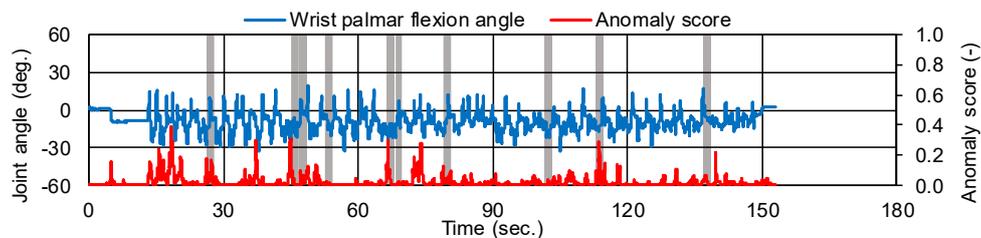


(b)ランダム間隔

図 4.4.1 被験者 1 名分のタスク A の肘関節屈曲角と異常スコアの経時変化



(a)タスク A



(b)タスク B

図 4.4.2 被験者 1 名分のランダム間隔条件の手関節掌屈角と異常スコアの経時変化

4.4.2 関節角度の最大値, 最小値, 実可動域の比較

表 4.4.1 に肘関節屈曲角, 前腕回内角, 手関節撓屈角, 手関節掌屈角の最大値, 最小値, 実可動域, および動作のばらつきの評価指標を示す. タスク間隔条件による関節角度の最大値の差はわずかであった. 対照的に, タスク A の手関節掌屈角の最大値はタスク B よりも有意に大きかった. 手関節撓屈角の実可動域は比較的小さかった. 各実験条件において, 前腕回内角の実可動域が最大となった.

表 4.4.1 肘関節屈曲角, 前腕回内角, 手関節撓屈角, 手関節掌屈角の最大値, 最小値, 実可動域, 参考可動域に対する実可動域の標準偏差の比

Joint angle (Reference ROM)	Task type	Task interval	Mean \pm SD			η (%)
			Maximum (deg.)	Minimum (deg.)	Actual ROM (deg.)	
Elbow flexion (Flexion: 145 deg.) (Extension: 5 deg.)	Task A	Constant	109.7 \pm 13.7	23.7 \pm 10.5	86.0 \pm 13.3	8.9
		Random	110.2 \pm 12.8	23.6 \pm 9.1	86.6 \pm 11.6	7.7
	Task B	Constant	109.6 \pm 14.4	17.8 \pm 8.9	91.8 \pm 13.2	8.8
		Random	108.2 \pm 11.3	18.5 \pm 8.4	89.6 \pm 17.0	11.3
Forearm pronation (Pronation: 90 deg.) (Supination: 90 deg.)	Task A	Constant	79.3 \pm 13.4	-25.4 \pm 26.4	104.6 \pm 28.2	15.7
		Random	78.7 \pm 11.3	-19.1 \pm 23.6	97.8 \pm 30.2	16.8
	Task B	Constant	72.9 \pm 17.4	-34.1 \pm 21.1	107.0 \pm 21.3	11.8
		Random	68.5 \pm 20.5	-37.7 \pm 23.9	106.2 \pm 23.8	13.2
Wrist radial flexion (Radial flexion: 25 deg.) (Ulnar flexion: 55 deg.)	Task A	Constant	18.4 \pm 16.5	-25.6 \pm 9.3	44.0 \pm 15.7	19.6
		Random	20.9 \pm 19.3	-28.3 \pm 9.0	49.2 \pm 15.2	19.0
	Task B	Constant	21.5 \pm 11.9	-20.4 \pm 6.1	41.9 \pm 11.0	13.8
		Random	21.3 \pm 11.9	-20.2 \pm 6.2	41.6 \pm 10.3	12.8
Wrist palmar flexion (Palmar flexion: 90 deg.) (Dorsal flexion: 70 deg.)	Task A	Constant	44.2 \pm 16.3	-43.9 \pm 17.2	88.1 \pm 27.1	17.0
		Random	43.1 \pm 15.7	-46.5 \pm 18.3	89.5 \pm 24.2	15.1
	Task B	Constant	22.3 \pm 14.4	-40.4 \pm 12.5	62.6 \pm 13.7	8.5
		Random	23.4 \pm 17.0	-41.8 \pm 14.5	65.2 \pm 14.0	8.8

4.4.3 異常スコアの平均および変動係数

表 4.4.2 は作業全体の各実験条件の異常スコアの平均値および変動係数を示す。表 4.4.3 は各関節角度の平均値および変動係数の分散分析の結果を示す。各関節角度について、ランダム間隔条件の平均異常スコアは一定間隔の条件よりも大きかった。同様にこれらの結果は、ランダムな間隔の一定間隔条件に対する比からも確認することができる。肘の屈曲では、ランダム間隔の平均値の一定間隔に対する比は比較的大きいが、平均異常スコアは他の関節角度と比較して比較的低くなった。分散分析の結果はタスク間隔条件の主効果が各関節角度で統計的に有意であることを示した。さらに、タスク条件の主効果は前腕回内角、手関節撓屈角、手関節掌屈角において統計的に有意であった。特異スペクトル変換が適用された全ての関節角度について、タスク条件とタスク間隔条件の交互作用は認められなかった。

表 4.4.2 実験全体にわたる各実験条件の異常スコアの平均と変動係数、およびランダム間隔の一定間隔に対する比

Joint angle applied SST	Task Type	Mean			CV		
		Constant ($\times 10^{-3}$)	Random ($\times 10^{-3}$)	Ratio of random against constant	Constant	Random	Ratio of random against constant
Elbow flexion	Task A	1.8 \pm 1.2	5.1 \pm 2.7	3.3 \pm 0.1	4.9 \pm 1.0	3.0 \pm 0.4	0.6 \pm 0.1
	Task B	1.3 \pm 0.5	3.9 \pm 2.2	3.3 \pm 2.3	4.6 \pm 1.4	2.9 \pm 0.6	0.7 \pm 0.2
Forearm pronation	Task A	11.2 \pm 6.6	15.7 \pm 10.6	1.5 \pm 0.7	2.6 \pm 0.5	2.1 \pm 0.2	0.8 \pm 0.2
	Task B	13.8 \pm 11.4	23.7 \pm 14.3	2.5 \pm 1.7	2.4 \pm 0.7	2.0 \pm 0.5	0.9 \pm 0.3
Wrist radial flexion	Task A	16.1 \pm 12.4	23.9 \pm 18.6	1.5 \pm 0.4	2.2 \pm 0.6	1.9 \pm 0.2	0.9 \pm 0.2
	Task B	26.0 \pm 15.8	31.4 \pm 19.5	1.4 \pm 0.8	2.0 \pm 0.4	1.9 \pm 0.4	1.0 \pm 0.2
Wrist palmar flexion	Task A	15.9 \pm 6.55	26.4 \pm 11.9	1.7 \pm 0.4	2.3 \pm 0.4	2.1 \pm 0.5	0.9 \pm 0.2
	Task B	12.4 \pm 5.84	19.9 \pm 8.20	1.8 \pm 1.0	2.4 \pm 0.5	1.9 \pm 0.3	0.8 \pm 0.2

表 4.4.3 各関節の異常スコアの平均値および変動係数の分散分析結果。統計的有意水準 5% で有意だった要因にはアスタリスク (*) がついている。

Joint angle applied SST	Factor	Mean anomaly score		CV of anomaly score	
		F value	P value	F value	P value
Elbow flexion	Work	F(1, 43) = 3.23	0.083	F(1, 43) = 0.56	0.16
	Task interval	F(1, 43) = 41.59	P<0.001*	F(1, 43) = 41.39	P<0.001*
	Work \times Task interval	F(1, 43) = 0.67	0.67	F(1, 43) = 0.029	0.87
Forearm pronation	Work	F(1, 43) = 4.80	0.036*	F(1, 43) = 1.37	0.25
	Task interval	F(1, 43) = 8.73	0.0061*	F(1, 43) = 11.68	0.0018*
	Work \times Task interval	F(1, 43) = 1.22	0.28	F(1, 43) = 0.079	0.78
Wrist radial flexion	Work	F(1, 43) = 9.34	0.0046*	F(1, 43) = 1.22	0.28
	Task interval	F(1, 43) = 5.39	0.027*	F(1, 43) = 2.32	0.14
	Work \times Task interval	F(1, 43) = 0.17	0.69	F(1, 43) = 0.38	0.54
Wrist palmar flexion	Work	F(1, 43) = 7.39	0.011*	F(1, 43) = 0.38	0.54
	Task interval	F(1, 43) = 24.18	P<0.001*	F(1, 43) = 15.64	P<0.001*
	Work \times Task interval	F(1, 43) = 0.72	0.40	F(1, 43) = 1.48	0.23

4.4.4 各実験条件のしきい値を超えた異常スコアの数

図 4.4.3 は肘関節屈曲角，前腕回内角，手関節撓屈角，手関節掌屈角に特異スペクトル変換を適用したときの各実験条件のしきい値を超えた異常スコア数を示す．異なるタスク間隔条件の作業姿勢の変化度合いを比較するために，全ての関節のしきい値を超えた異常スコアの数と平均値を，実験条件ごとに計算した．タスク A において，一定間隔およびランダム間隔条件下の全ての関節のしきい値を超えた異常スコアの数と平均値はそれぞれ，162 および 180 で，ランダム間隔条件の方が一定間隔条件より 11.7%増加した．タスク B において，一定間隔およびランダム間隔条件下の全ての関節のしきい値を超えた異常スコアの数と平均値はそれぞれ，165 および 177 で，ランダム間隔条件の方が一定間隔条件より 7.0%増加した．全体的に，被験者がランダム間隔条件でなく一定間隔条件で作業をした時にしきい値を超える異常スコアは少なくなった．ただし，一定間隔条件でのタスク A の手関節掌屈角のしきい値を超えた異常スコア数はランダム間隔条件よりも大きかった．さらに，一定間隔条件のタスク B の手関節撓屈角のしきい値を超えた異常スコア数はランダム間隔条件よりも大きかった．これらの実験結果は，参加者の作業動作がタスク間隔条件の順序効果の影響を受けた可能性を示唆している．実験開始時の作業姿勢の変化は，試行錯誤しながら動作パターンを学習していたため，作業動作に慣れるようになった時よりも大きくなった．特に，実験で球状の軽量物を取得する際，手首の関節角度は大きく変化する可能性がある．ただし，分散分析の結果は，特異スペクトル変換を肘関節屈曲角に適用した場合のみ，タスク間隔条件の主効果を示している．

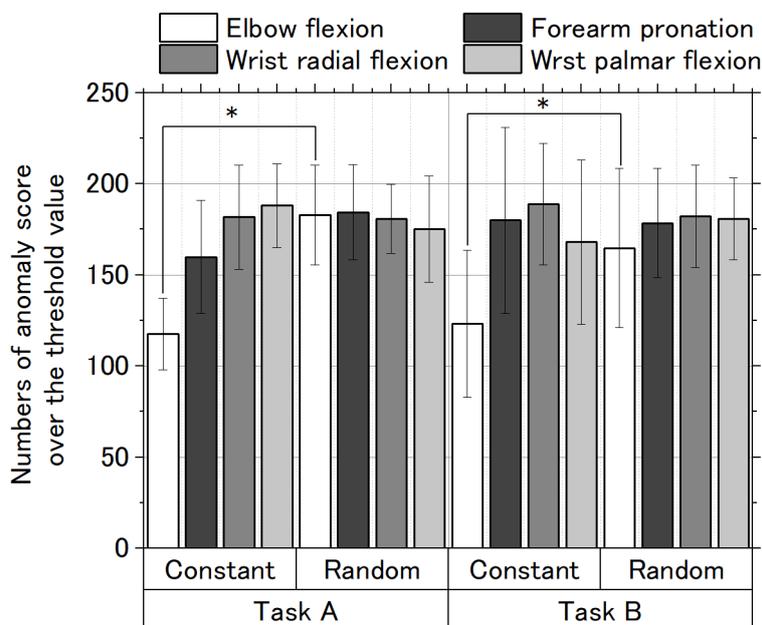


図 4.4.3 各関節角度に特異スペクトル変換を適用したときの各実験条件におけるしきい値を超えた異常スコアの数

4.4.5 ラグLの採択率

図 4.4.4 は両タスク条件下での各タスク間隔条件の各Lの採択率を示している。一定条件下では、最大の採択率は、両方のタスク間隔条件において $L = 150$ の時であり、基本的なタスク間隔との一貫性を示した。

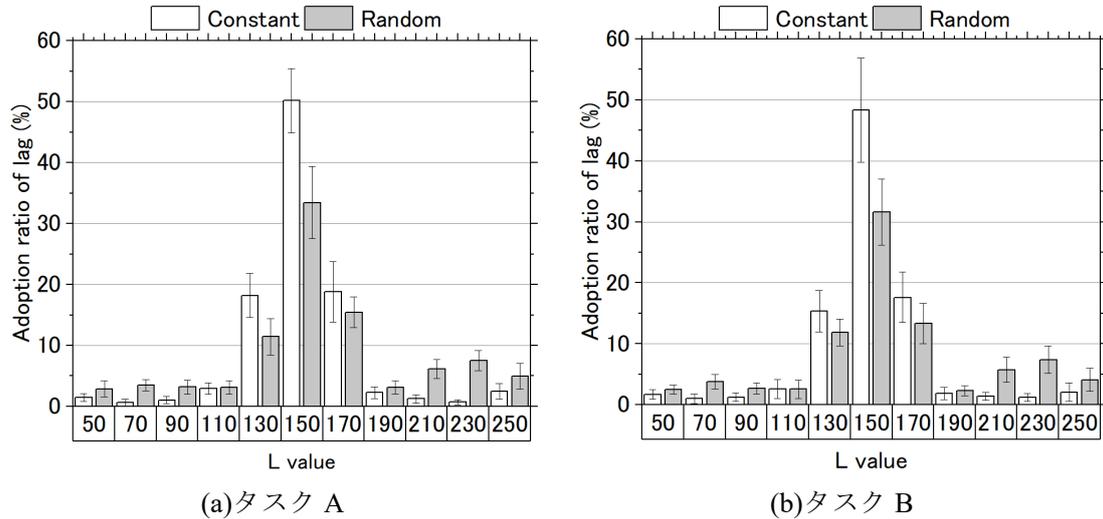


図 4.4.4 両タスク条件の各Lの採択率

4.5 考察

4.5.1 異常スコアと作業姿勢のばらつきとの関係

しきい値を超える異常スコアの値によれば、特異スペクトル変換を肘関節屈曲角に適用した場合のみ、分散分析によるタスク間隔条件の主効果が認められた。全ての関節のランダム間隔条件の平均異常スコアは一定間隔条件よりも大きかった。ただし肘関節屈曲角の場合、一定条件とランダム条件の異常スコアの差は他の関節よりも小さかった。各関節について、一定条件の変動係数はランダム条件の変動係数よりも大きかった。平均異常スコアが増加したにもかかわらず変動係数が減少したことは、一定間隔条件とランダム条件間の異常スコアの標準偏差が小さかったことを示唆している。一方で、他の関節の異常スコアの変動係数は一定間隔条件とランダム間隔条件の間の差が小さいことを示した。肘関節を除く関節の結果は、ランダム間隔条件の標準偏差と平均異常スコアが一定間隔条件の標準偏差と平均異常スコアを超えたことを示している。したがって、しきい値を超える異常スコアの数の結果から、肘関節屈曲角を除いた関節角度におけるタスク間隔条件の主効果は認められなかった。

以上の結果をもとに、動作のばらつきと異常スコアの関係について考察する。Taylor et al.[151]は日常生活における上肢の動作のばらつきを調査し、最小の動作のばらつきが手首に関連する関節角度であることを報告した。ただし、関節の可動域の相対値を取った場合、肘関節屈曲角のばらつきが最も小さくなった。したがって、比較的動作のばらつきが小さい

関節角度を観察する場合、作業中の作業姿勢の変化の検出が容易であった。対照的に比較的高い動作のばらつきを示す関節の場合、計算された異常スコアを使用して作業姿勢の問題と動作のばらつきを区別することが困難になった。したがって、各関節角度の動作のばらつきに応じてしきい値を変更し、作業姿勢の問題を検出する必要がある。

4.5.2 ラグ L の最適なパラメータの選択

本研究では主にラグ L に焦点を当て、 L の変化が異常スコアにどのように影響するかを検証した。 L の採択率は両タスク条件共に一定条件下では $L = 150$ の時に最大となった。ウィンドウ長 M の選択方法は特異スペクトル解析に関する先行研究で検証されている。Kugiumtzis[147]、ウィンドウ長は信号のピーク間の平均時間に従って設定するべきであると提案した。Hassani et al.[149]はウィンドウの長さが信号の周期に比例する必要があることを報告した。各試行間の作業姿勢を比較するために、ラグ L が作業周期と一致する必要があることを本研究の結果は示唆している。ランダム条件ではタスク間隔が 1.5 秒に減少するため、ラグ L の採択率は、通常の作業間隔時に選択されるラグ $L = 150$ から 1.5 秒分 ($L = 75$) を引いた、または足したラグの値の採択率が増加した。したがって、ランダム間隔条件の結果は各タスク間の作業姿勢を比較するために、ラグ L が作業周期と一致する必要があることを示唆している。

$L = 130$ および $L = 170$ の採択率は一定間隔条件下で作業を実施したとしても、人間の作業周期が普遍的にばらつくことを示唆している。手作業の作業間隔が何らかの分布に従うと仮定すると、ラグ L の最適なパラメータはその分布から選択する必要がある。したがって、正確に過去と現在の作業姿勢を比較するためにタスクに対応する分布を事前に推定する必要がある。MOST (Maynard Operation Sequence Technique) [154]などの作業測定法に基づく標準時間は、基本的なタスク間隔を決定するために利用できる可能性がある。ただし、手作業のタスク間隔の分布（または、ばらつき）を推定するためには、さらなる調査が必要である。

4.6 小括

本研究は作業全体における作業姿勢の変化の検出に対する特異スペクトル変換の有用性を検証した。全ての関節角度のランダム間隔条件の異常スコアの平均値は、一定間隔条件の平均異常スコアよりも大きかった。ランダム間隔条件の全ての関節角度のしきい値を超えた異常スコアの数の平均は一定間隔条件の平均よりも大きかった。これらの結果は特異スペクトル変換がタスク全体の姿勢の変化の検出を補助できることを示唆している。ただし、 $+3\sigma$ の範囲に基づくしきい値を超える異常スコアの数から示されているように、タスク間隔条件による主効果は肘関節屈曲角に特異スペクトル変換を適用した場合のみで認められた。動作のばらつきが大きい関節角度の場合、従来の特異スペクトル変換では、作業姿勢の問題と動作のばらつきの違いを区別することはできなかった。これらの結果は、時系列で作業姿勢の問題を正確に推定するために、しきい値を決定するときに各関節角度の動作のばらつきを考慮する必要があることを示唆している。

ラグ L の採択率は選択される L の値が作業周期の時間に対応している必要があることを示している。この結果は先行研究のウィンドウ長の選択方法と関連し、ラグ L の選択の妥当性を示している。ただし、人間の動作を伴う作業周期は一定ではなく様々な分布を持つ。本研究の結果は過去と現在の作業姿勢を比較するために、タスクに対応する作業周期の分布をあらかじめ推定しておく必要があることを示唆している。

結論として、本研究は特異スペクトル変換がタスク全体の作業姿勢の変化の検出を補助し、ラグのパラメータは作業周期に従って決定する必要があることを示した。ただし、作業姿勢の問題の検出を改善するために、動作のばらつきや作業周期の分布の考慮などいくつかの課題に対処する必要があることが示された。

第5章 時系列データを対象とした異常検知手法による作業動作評価： 特異スペクトル変換に基づく経時的な作業姿勢変化の検出

5.1 緒論

第4章では時系列データを対象とした異常検知手法を用いた作業姿勢評価として、突発的な姿勢変化を誘発する実験を実施し、特異スペクトル変換の有用性を検討した。近年みられるような反復作業では筋疲労の進行に伴い動作のばらつきの増加などの緩やかな姿勢の変化が発生する。そのような長期にわたる変動は、突発的な姿勢変化の検出と同様の手法では評価することが困難であり、人間の動きの長期的な動作変動の履歴を考慮できるように手法を拡張する必要がある。したがって本章では、第4章と比較して、より長時間にわたる反復作業を対象とし、筋疲労の変化に応じた作業姿勢および動作の緩やかな変化を検出する問題に対して異常検知手法の応用を試みる。

反復作業の実施は筋疲労を発生させ、筋疲労は筋骨格系障害 (Musculoskeletal disorders) 発症のリスク要因となりうる[155][156][157]。また、筋疲労は動作のばらつきの変化を引き起こし、滑らかで制御された動作の生成能力が低下することが報告されている[158][159]。筋疲労抑制のための人間工学的介入として、動作類似性の低下、すなわち動作のばらつきの増加が推奨されている[6]。実際に、動作のばらつきの大きい作業者が筋疲労と痛みの発生が低いこと[160][161]や負傷からの復帰が早いこと[162]がいくつかの先行研究により報告されている。これらの研究は、反復作業における筋骨格系障害発症リスクが動作のばらつきの増加によって減少することを示している[163][6]。したがって、反復作業中の筋疲労の把握は、筋疲労に応じた動作のばらつきの経時変化を推定から行うことが可能である。

動作のばらつきの評価法として、近似またはサンプルエントロピーに基づく評価法[161]、非線形動力学に基づく評価法[164]、角度-角速度位相プロットに基づく評価法[165]、Goal Equivalent Manifolds と呼ばれる手法[166][167]などが用いられている。また、作業姿勢の構造の変化の識別と動作のばらつきの検出のために主成分分析が有効な手法であることが報告されている[168]。しかし、これらの手法は動作のばらつきの経時変化の評価には対応していない。

本章では、反復作業における筋疲労に応じた動作のばらつきの経時変化の推定に異常検知手法を応用することを試みる。前章にて用いた特異スペクトル変換は人間の動作の現在のパターンと過去のパターンを比較する手法であるが、比較する過去のパターンは時系列中の一部のタスクに限定される。したがって、特異スペクトル変換では長期間の反復作業における時間経過に伴う緩やかな作業姿勢の変化を評価することは困難である。そこで本研究では、反復作業における人間の動作のより長期的な履歴を考慮した特異スペクトル変換ベースの新しい異常スコアの計算方法を提案し、その有用性を反復的な軽量物取り置き作業を対象に明らかにすることを目的とする。具体的に、2種類のタスク条件において10分間の軽量物取り置き作業を実施し、作業姿勢および主観的負担感について計測した。その後、

提案手法で計算された異常スコアベースの動作のばらつきの推定結果と従来法による動作のばらつきおよび従来の特異スペクトル変換で計算された異常スコアと比較し、提案手法の有用性を明らかにする。

5.2 理論

5.2.1 特異スペクトル変換の概要

Ide and Inoue[107]によって提案された特異スペクトル変換は変化点スコアに基づいて元の時系列データを新しい時系列データへ変換する手法である。ある時系列 $\mathcal{T} = \{x(1), x(2), \dots, x(t), \dots, x(N)\}$ と窓幅 M を用いた連続した部分時系列 $\{x(t-M), \dots, x(t-2), x(t-1)\}$ を考える。連続した部分時系列をベクトルを $\mathbf{s}(t-1) = (x(t-M), \dots, x(t-1))^T$ と定義した時、2つのハンケル行列、履歴行列 $\mathbf{X}(t)$ とテスト行列 $\mathbf{Z}(t)$ はそれぞれ以下のように定義される。

$$\mathbf{X}(t) \equiv [\mathbf{s}(t-n), \dots, \mathbf{s}(t-2), \mathbf{s}(t-1)]. \quad (5.1)$$

$$\mathbf{Z}(t) \equiv [\mathbf{s}(t+L+M-1), \mathbf{s}(t+L+M), \dots, \mathbf{s}(t+L+M+k-1)]. \quad (5.2)$$

履歴行列とテスト行列はそれぞれ人間の動作の過去と現在のパターンを示す。 L はラグと呼ばれる履歴行列とテスト行列の相互位置を決める非負定数である。

変化点スコアまたは異常スコアは2つの主部分空間の差として定義される。時刻 t における履歴行列とテスト行列の主部分空間 $\mathbf{U}_r(t)$ および $\mathbf{Q}_m(t)$ はそれぞれ以下のように定義される。

$$\mathbf{U}_r(t) \equiv [\mathbf{u}_1(t), \mathbf{u}_2(t), \dots, \mathbf{u}_m(t)]. \quad (5.3)$$

$$\mathbf{Q}_m(t) \equiv [\mathbf{q}_1(t), \mathbf{q}_2(t), \dots, \mathbf{q}_m(t)]. \quad (5.4)$$

ここで、 $\mathbf{u}_r(t)$ および $\mathbf{q}_m(t)$ は履歴行列 $\mathbf{X}(t)$ とテスト行列 $\mathbf{Z}(t)$ を特異値分解して得られる左特異ベクトルである。 r および m は特異値分解をして得られる左特異ベクトルの本数を示す。時刻 t における異常スコア $a(t)$ は以下の式で計算される。

$$a(t) = 1 - \|\mathbf{U}_r(t)^T \mathbf{Q}_m(t)\|_2. \quad (5.5)$$

定義より、異常スコア $a(t)$ は0から1の範囲の値をとる。異常スコアが小さい時は過去のパターンと比較して変化は小さく、異常スコアが大きい時は現在の時刻の動作は過去のパターンと異なることを示す。

5.2.2 新しい異常スコアの計算方法の提案

異なるタスク間の作業姿勢の違いを明らかにするために履歴行列の正確な選択が重要である。特異スペクトル解析を用いた変化点スコアの計算において、履歴行列は全ての動作データを示す行列やおよび主要なデータパターンを抽出した行列として定義される[169]。しかし、これらの履歴行列の選択方法にはいくつかの問題点がある。例えば、データ全体を履歴行列とする手法はタスク間の作業姿勢を比較する際に不要な動作パターンを含む可能性がある。また、主要な動作パターンを抽出した履歴行列は取り出す動作パターンが異なることによって異常スコアが大きく異なる場合がある。したがって、正確な異常スコアを計算するために、長期間の反復作業における人間の動作のより長期的な履歴を考慮することが重要である。より長期間の人間の動作履歴を考慮するために、本研究では以下の式で示される異常スコアの新しい計算方法を提案する。

$$a(t) = \frac{\sum_{i=1}^N 1 - \|\mathbf{U}_r(t - (i-1)L)^T \mathbf{Q}_m(t)\|_2}{N}. \quad (5.6)$$

ここで、 N は時刻 t をラグ L で割った時の商を示す。ここで、ラグ L は作業全体から抽出されるタスクにかかった時間の代表値と一致する必要がある。

5.3 実験方法

5.3.1 被験者

被験者は11名の右利きの男性であった。被験者の年齢、身長、体重の平均±標準偏差は、 23.1 ± 1.5 歳、 1732 ± 42 mm、 67.4 ± 9.0 kg であった。また、被験者の手長、前腕長、上肢長は 185 ± 11 mm、 441 ± 17 mm、 740 ± 27 mm であった。なお、本実験は首都大学東京日野キャンパスの研究安全倫理委員会の承認を得て実施した。実験を始める前に被験者に実験の概要を説明し書面による同意を得た。

5.3.2 実験条件

本研究では座位姿勢で球状の軽量物（直径 35 mm、重さ 8 g）を 10 分間移動させる作業を実施した。被験者は2種類のタスク（タスク A、タスク B）を実施した。タスク A は左側のカゴから右側のカゴへ軽量物を移動させ、タスク B は被験者から見て奥のカゴから手前のカゴへ軽量物を移動させた。

実験は被験者が座位姿勢で解剖学的基本姿勢を保持した条件で開始した。5 秒間の解剖学的基本姿勢の保持後、被験者は事前に指示されたタスク条件で任意の作業ペースで軽量物の取り置き作業を開始した。被験者は軽量物の取り置き作業を続けながら、20 秒に 1 回、右上肢の主観的負担感について Borg CR10[139]を用いて口頭で回答した。10 分間の作業終了後、被験者は解剖学的基本肢位を 5 秒間保持し、1 条件を終了した。疲労の蓄積の影響を除外するために、次のタスク条件までには十分な休憩を設けた。具体的に、被験者はタスク終了後、最低 3 分間の休憩を取り、被験者が右上肢に不快感が残っていないと自己申告した場合のみ次の条件を開始し、不快感が残っている場合は不快感がなくなるまで休憩を延長した。

5.3.3 測定項目と解析方法

5.3.3.1 作業姿勢計測と動作のばらつきの推定

磁気式 3 次元位置測定装置（trakSTAR, Ascension Technology Corp.）を用いて、腰部、胸部、右上肢、右前腕、右手の 3 次元位置と方位をサンプリング周波数 50 Hz で取得した。各身体セグメントについて、trakSTAR のレシーバは先行研究[150]を参考に図 5.3.1 のように配置した。続いて、測定された各身体セグメントの方位を 3 次元剛体リンクモデルに対して適用し、体幹部と右上肢の関節角度を計算した。

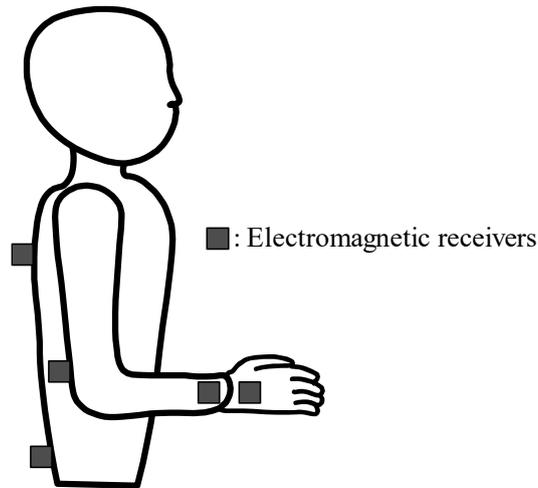


図 5.3.1 レシーバ貼付位置

Wagner et al.の先行研究[165]に基づき，正規された角度-角速度位相プロットのベクトル長の標準偏差を動作のばらつきとして推定した．正規化された角度および角速度は以下の式で計算した．

$$\theta_{norm} = \frac{2\theta - (\theta_{max} + \theta_{min})}{\theta_{max} - \theta_{min}}, \quad (5.7)$$

$$\omega_{norm} = \frac{2\omega - (\omega_{max} + \omega_{min})}{\omega_{max} - \omega_{min}}, \quad (5.8)$$

ここで， θ_{max} と ω_{max} は各タスクの関節角度および角速度の最大値を示し， θ_{min} と ω_{min} は各タスクの関節角度および角速度の最小値を示す．角速度は実験における関節角度の時系列データから計算された．正規化された角度-角速度位相角のベクトル長は以下の式で計算される．

$$\lambda = \sqrt{\theta_{norm}^2 + \omega_{norm}^2}. \quad (5.9)$$

本研究では時刻 t における動作のばらつきを，タスク 20 秒ごとの標準偏差として定義した．ただし，参加者が解剖学的基本姿勢を保持した 5 秒間は個別に計算した．動作のばらつきの被験者間平均と標準偏差はタスク条件ごとに計算された．

5.3.3.2 特異スペクトル変換を用いた異常スコアの計算

特異スペクトル変換により各関節角度の異常スコアを MATLAB R2019a を用いて計算した。特異スペクトル変換に用いたパラメータはそれぞれ、 $M = 50$, $L = 75$, $n, k = M/2$, and $r, m = 3$ であった。 M , n および k は観測された1タスク当たりの時間が約1.5秒であったことを踏まえ、平均的なタスク間隔と一致するように定義する必要があると報告した先行研究[147][149]に従い定義した。 L の値は1タスクを完了するまでに必要な標準的な時刻を反映している。提案手法の有用性を検討するために、計算された異常スコアは従来手法である2種類の履歴行列を用いて計算された異常スコアと比較された。本研究では、2種類の履歴行列をそれぞれ、“全体履歴行列”および“抽出履歴行列”と定義した。全体履歴行列はタスク全体の人間の動作を示している。抽出履歴行列は軽量物の置き作業開始から10秒間の動作パターンを示している。

経時変化に伴う異常スコアの傾向を説明するために、時刻 t の異常スコアの中央値を時刻 t までの異常スコアの履歴から計算した。次いで、被験者11名分の平均的な異常スコアの時間変化を計算した。

5.3.3.3 作業ペースの推定

作業ペースの推定のために、軽量物を取った時刻を被験者の右手首の位置と速度に基づいて MATLAB R2019a を用いて推定した。作業ペースは現在の取得時刻と直前の取得時刻の差として定義された。次いで、各タスク条件下で100秒ごとに作業ペースの中央値を計算し、その後、被験者11名分の平均作業ペースを計算した。

5.3.3.4 主観評価

作業中の主観的な負担感を明らかにするために、被験者は作業中20秒ごとに右上肢の主観的な負担感を Borg CR10[139]を用いて口頭で回答した。その後、被験者11名分の主観的な負担感の中央値を計算した。

5.3.3.5 統計解析

反復作業によって引き起こされる筋疲労が動作のばらつき、異常スコア、作業ペース、および主観評価に与える影響について明らかにするために、各評価指標の最終値を分散分析を用いて解析した。一元配置分散分析を動作のばらつき、作業ペースおよび主観評価の結果の統計解析に用いた。実験因子はタスク条件であった。加えて、一元配置分散分析を異常スコアの統計解析のために使用した。実験因子は異常スコアの計算方法であった。全ての統計解析において、統計的有意水準は5%に設定し、統計解析には Origin Pro 2020 (OriginLab Corporation)の統計解析パッケージを用いた。

5.4 結果

5.4.1 動作のばらつき

図 5.4.1 の(a)から(d)は被験者 11 名の各タスクにおける動作のばらつきの平均値を示している。全ての関節角度でタスクの開始時に動作のばらつきが大きくなった。両方のタスクの下で肩関節外転角の動作のばらつきはタスク全体にわたって一定であり、タスク条件による主効果は認められなかった[F(1, 21)=1.663, p=0.212]。肩関節屈曲角の動作のばらつきは各タスク条件において一定であり、タスク B の方がタスク A よりもわずかに大きかった。ただし、タスク条件の主効果は認められなかった[F(1, 21)=1.477, p=0.238]。肩関節内旋角の動作のばらつきはタスク A では一定であったが、タスク B では時間とともに減少した。分散分析の結果から、タスク条件の主効果が認められた[F(1, 21)=4.666, p=0.043]。肘関節屈曲角の動作のばらつきは時間とともに増加し、タスク B の方がタスク A よりも大きかった。ただし、タスク条件による主効果は認められなかった[F(1, 21)=3.001, p=0.099]。

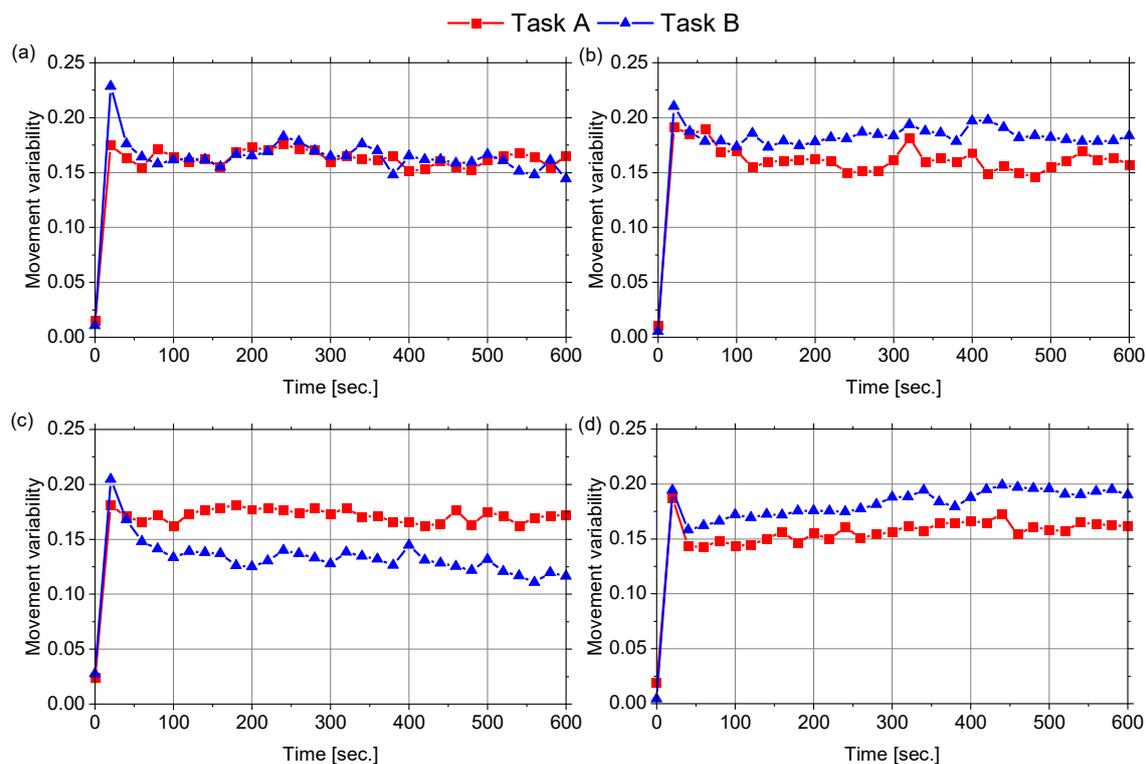


図 5.4.1 各関節角度の各タスク条件における動作のばらつきの平均値：
(a)肩関節外転角，(b)肩関節屈曲角，(c)肩関節内旋角，(d)肘関節屈曲角

5.4.2 異常スコア

5.4.2.1 タスク A における異常スコア

図 5.4.2 の(a)から(d)は被験者 11 名のタスク A における平均異常スコアを示している。ほとんどの関節角度の異常スコアは実験の開始時に増加した。これは実験開始時には、被験者が解剖学的基本姿勢を保持しているため、反復作業中の作業姿勢と大きく異なったことが原因である。そのため、タスク開始から 100 秒以降の異常スコアの傾向に焦点を当てる。

肩関節外転角の場合、提案手法および全体履歴行列により計算された異常スコアは一定で、提案手法の異常スコアは全体履歴行列により計算された異常スコアよりも大きかった。抽出履歴行列により計算された肩関節外転角の異常スコアは時間とともに増加した。分散分析の結果は計算方法の主効果が有意であることを示した[F(2, 32)=3.752, p=0.035]。

肩関節屈曲角の場合、提案手法および抽出履歴行列で異常スコアが計算された時に、異常スコアは時間とともに増加した。ただし、提案手法の異常スコアは抽出履歴行列の異常スコアよりも大きかった。全体履歴行列で計算された肩関節屈曲角の異常スコアは一定であった。分散分析の結果は計算方法による主効果が有意であることを示した[F(2, 32)=3.885, p=0.032]。

肩関節内旋角の異常スコアの時間変化は全体履歴行列で計算することで減少し、抽出履歴行列を使用するとわずかに増加し、提案手法で計算すると一定であった。ただし、分散分析の結果は計算方法の主効果が有意でないことを示した[F(2, 32)=0.296, p=0.746]。

肘関節屈曲角の場合、全体履歴行列および抽出履歴行列を用いて計算された異常スコアはタスク全体にわたって一定であったが、提案手法で計算された異常スコアは時間とともに減少した。分散分析の結果は計算方法の主効果が有意であることを示した[F(2, 32)=47.890, p<0.001]。

5.4.2.2 タスク B における異常スコア

図 5.4.3 の(a)から(d)は被験者 11 名のタスク B における平均異常スコアを示している。ほとんどの関節角度の異常スコアは実験の開始時に増加した。タスク B の開始から 100 秒後の異常スコアの傾向をタスク A と同じ方法で調査した。

肩関節外転角の場合、異常スコアは提案手法と 2 つの履歴行列で計算した場合、タスク全体で一定のままであった。ただし、提案手法の異常スコアは、両方の履歴行列の異常スコアよりも大きかった。分散分析の結果は計算方法による主効果が有意であることを示した[F(2, 32)=27.590, p<0.001]。

肩関節屈曲角の場合、提案手法および抽出履歴行列によって計算された異常スコアは時間とともにわずかに増加した。提案手法で計算された異常スコアは抽出履歴行列によって計算された異常スコアよりも大きかった。全体履歴行列によって計算された場合、肩関節屈曲角の異常スコアはタスク全体にわたってほとんど一定であった。分散分析の結果は計算方法による主効果が有意であることを示した[F(2, 32)=6.300, p=0.005]。

肩関節内旋角の場合，提案手法で計算された異常スコアは両方の履歴行列を用いて計算された異常スコアよりも大きく，時間とともに増加した．全体履歴行列を用いて計算された異常スコアはタスク全体にわたってほとんど一定であった．抽出履歴行列を用いて計算された異常スコアは時間とともにわずかに増加した．しかし，分散分析の結果は計算方法による主効果が有意であることを示さなかった[F(2, 32)=1.911, p=0.165].

肘関節屈曲角の場合，提案手法および全体履歴行列によって計算された場合の異常スコアは時間とともに減少した．提案手法によって計算された異常スコアは全体履歴行列を使用して計算された異常スコアよりも大きかった．抽出履歴行列を用いて計算された異常スコアは時間とともにわずかに増加した．分散分析の結果は計算方法による主効果が有意であることを示した[F(2, 32)=73.708, p<0.001].

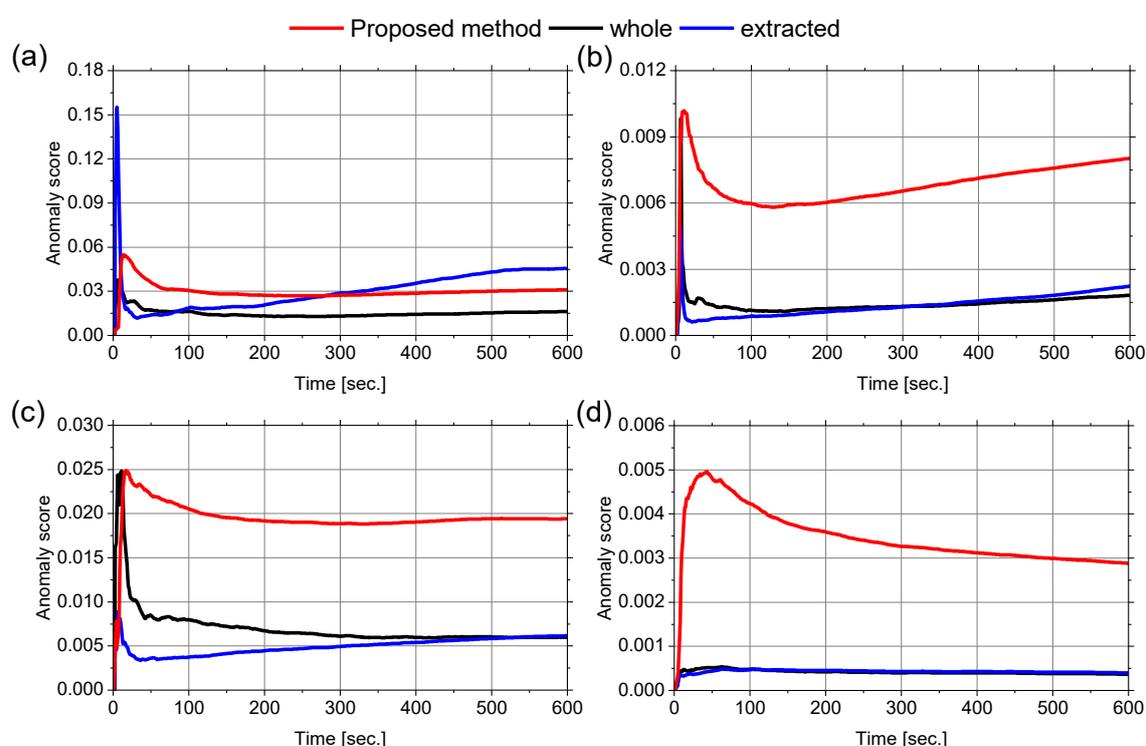


図 5.4.2 各関節角度のタスク A における異常スコアの平均値：
 (a)肩関節外転角，(b)肩関節屈曲角，(c)肩関節内旋角，(d)肘関節屈曲角

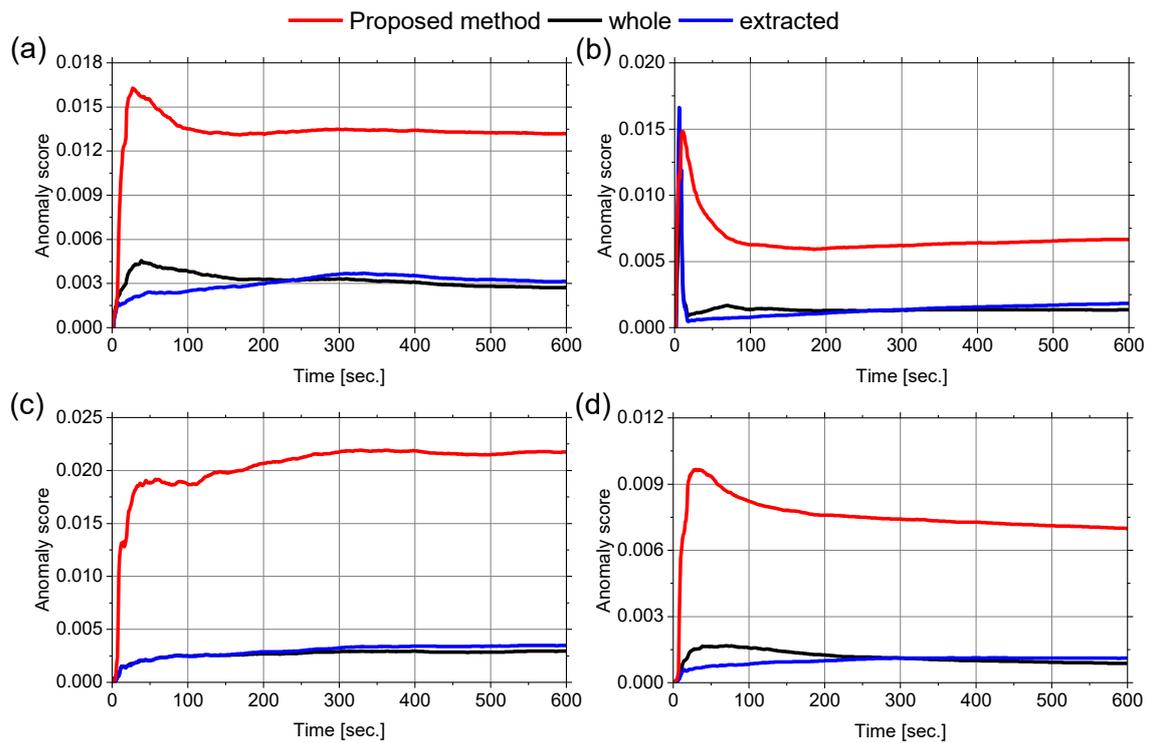


図 5.4.3 各関節角度のタスク B における異常スコアの平均値：
 (a)肩関節外転角, (b)肩関節屈曲角, (c)肩関節内旋角, (d)肘関節屈曲角

5.4.3 作業ペース

図 5.4.4 は各タスク条件の平均作業ペースを示している。タスク A では、後半の作業ペースは前半の作業ペースと比較して減少した。タスク B では、タスク開始から 100 秒の平均作業ペースとタスク開始から 600 秒の平均作業ペースが等しかった。しかし、タスク開始から 600 秒の平均作業ペース 300 秒の平均作業ペースよりも短かった。タスクにおける平均作業ペースの最大値とタスクの最終値を比較した場合、タスク A では約 0.15 秒減少し、タスク B では約 0.08 秒減少した。分散分析の結果、タスク条件による主効果は有意ではなかった[F(1, 21)=0.115, p=0.738]。

5.4.4 主観評価

図 5.4.5 は右上肢の主観的負担感の中央値およびその増加率を示している。主観的負担感 は時間とともに増加し、主観的負担感の最終値はタスク B の方がタスク A よりも大きかった。タスク A の主観的負担感 は実験開始から 400 秒以降で一定となった。各タスク条件の主観的負担感の増加率のプロットを線形近似した。右上肢の主観的負担感の増加率は両タスク条件共に時間とともに減少した。分散分析の結果、タスク条件の主効果が認められた [F(1, 21)=4.938, p=0.038]。

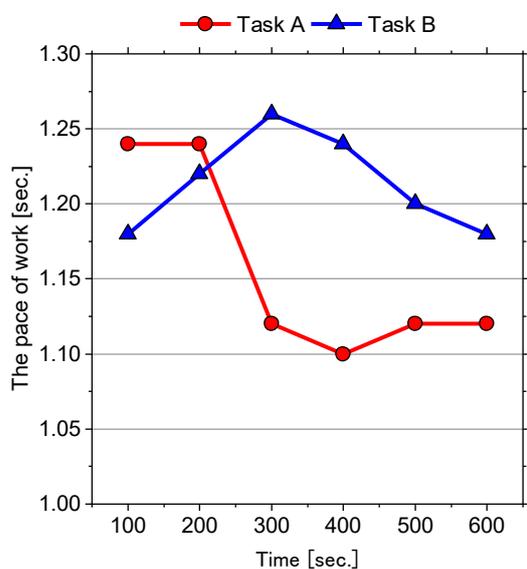


図 5.4.4 各タスク条件の平均作業ペース

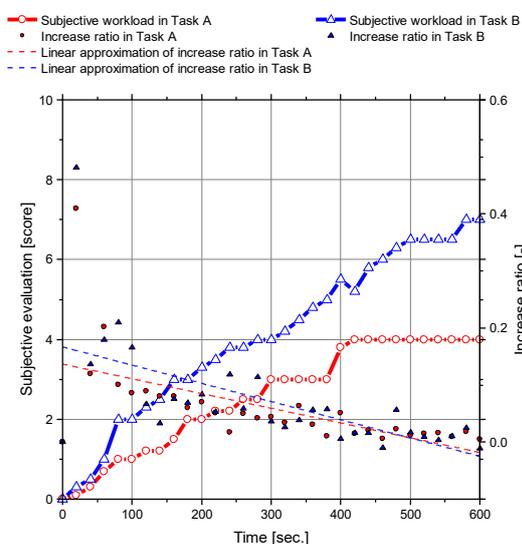


図 5.4.5 右上肢の主観的負担感の中央値とその増加率

5.5 考察

5.5.1 提案手法を用いた動作のばらつきの推定の有用性

提案手法を用いた場合、タスク A およびタスク B では、肩関節屈曲角と肩関節内旋角の異常スコアが時間とともに増加した。さらに、肘関節屈曲角の異常スコアは両方のタスク条件で時間とともに減少した。一方従来手法[165]を使用して計算を行った場合、肘関節屈曲角の動作のばらつきは時間とともに増加したが、肩関節に関する動作のばらつきは一定または時間とともに減少した。提案手法を使用した異常スコアの傾向は従来手法による動作のばらつきの傾向と一致しなかった。Srinivasan and Mathiassen[129]は、多関節運動を実行する上で冗長な自由度から動作のばらつきが増加することを報告した。さらにいくつかの研究では、反復作業実施中の筋疲労の進行に伴い、肩関節の動作のばらつきが増加することを報告している[170][171]。図 5.4.5 に示されている主観的負担感は両方のタスク条件で時間とともに増加した。提案手法で計算された肩関節の異常スコアと主観的負担感の関係は、筋疲労の進行に伴い肩関節の動作のばらつきが増加することを報告したいくつかの先行研究の知見と一致した。さらに図 5.4.5 に示すように、主観的負担感の増加率は両方のタスク条件下で時間とともに減少した。提案手法による肩関節の異常スコアと主観的作業負荷の増加率の関係は、肩関節の動作のばらつきの増加が反復作業における筋疲労の進行を抑制することを示している。この知見は、動作のばらつきの増加が反復作業における筋骨格系障害の発生の抑制に有効であるという先行研究[6]の知見と一致している。

対照的に、従来手法で推定された動作のばらつきの傾向はいくつかの先行研究の傾向と一致せず、両タスク条件下で時間とともに増加した。Wagner et al.[165]によって開発された従来手法では、関節角度および角速度の最大値および最小値を使用して、動作のばらつきを計算した。被験者が反復作業を実行することで、習熟が発生し、1タスク当たりには要する時間は減少する[171]。本研究の結果では、作業の後半で作業ペースが減少した(図 5.4.4)。したがって、肘関節屈曲角の動作のばらつきと作業ペースの関係は、動作のばらつきの増加が角速度の変化の増加によって引き起こされたことを示唆している。Srinivasan et al.[172]は、反復作業における作業ペースが増加するのに伴い、動作のばらつきが減少することを報告した。肘関節屈曲角の異常スコアと作業ペースの関係について、提案手法で得られた傾向は作業ペースの増加に応じて動作のばらつきが減少するという先行研究の結果[172]と一致している。提案手法の結果は、反復作業中に筋疲労が進行するのに伴い肩関節および肘関節の異常スコアがそれぞれ増加および減少することを示した。これは、肩関節の動きが時間とともに変化していることを示唆している。同様に先行研究では、動作のばらつきの増加が筋骨格系障害予防に有効であることを報告している[6]。したがって、提案手法の結果は、反復作業中の筋疲労の影響を低減する上で肩関節の動きが肘関節と比較して有意に変化することを示唆している。

Longo et al.[168]は主成分分析が動作のばらつきを検出し、姿勢構成の変化を識別するための適切な方法であることを報告した。主成分分析と特異値分解は数学的に同等な処理を

行っていることが知られている。したがって、特異値分解に基づく提案手法は動作のばらつきの変化を検出するために有効な手法であると判断することができる。さらに提案手法は時系列データに対応しているため、反復作業における動作のばらつきの経時変化を推定するためにより優れた手法である可能性がある。抽出履歴行列を使用した場合、肩関節外転角の異常スコアは時間とともに増加した。対照的に、提案手法を使用して計算した異常スコアはタスク全体でほぼ一定であった。これは、全体履歴行列を使用して計算した異常スコアの傾向と一致している。つまり、提案手法で計算された異常スコアは反復作業中の人間の動作の全体的な傾向を反映できることが示唆された。また、抽出履歴行列を用いた場合、作業全体から一部の動作区間を抽出するため、抽出した動作パターンが仮に作業全体の動作の傾向から外れている時に他の動作区間における異常スコアが過剰に増加する可能性がある。本研究の提案手法はこのような局所的な作業姿勢の問題の影響を受けないことが示唆された。したがって、これらの知見は、提案手法が長期的な反復作業における動作のばらつきの変化を検出するためのより適切な方法であることを示唆している。

5.5.2 今後の課題

動作のばらつきの変化に基づいて作業者の身体負担および筋疲労を推定するために、人間工学的観点から考慮した特定のしきい値に基づいて、計算された異常スコアを識別する必要がある。そのしきい値は従来の筋疲労評価法と関連付けて定義する必要がある。例えば、最大持続時間[173]および筋線維の運動単位に基づく理論モデル[174][175]が挙げられる。これらの方法は一般的ではあるがいくつかの解決が必要な問題点がある。最大保持時間は疲労が時間とともに非線形に変化する場合、筋疲労を過小評価する可能性がある。Rashedi and Nussbaum[176]は Xia and Frey-Law[175]によって提案された筋疲労モデルを様々な条件下で適用するには、低から中程度のレベルの筋疲労の追加の測定が必要であることを報告した。従来法による筋疲労の評価指標によるしきい値を提案するためには、例えば、本研究のような低負荷かつ高反復の作業における筋疲労モデルと提案手法による異常スコアの結果の関係を明らかにする必要がある。

5.6 小括

本研究は反復作業中の人間の動作のより長期的な履歴を考慮した特異スペクトル変換に基づいて異常スコアを計算する新しい方法を提案した。提案された方法の有用性を検証するために、計算された異常スコアを従来手法で計算された動作のばらつきと従来の特異スペクトル変換で計算された異常スコアと比較した。提案手法を用いて異常スコアを計算した場合、左側のカゴから右側のカゴへ軽量物を移動させたタスク A の肩関節屈曲角と奥のカゴから手前のカゴへ軽量物を移動させたタスク B の肩関節内旋角の異常スコアは時間とともに増加し、肘関節屈曲角の異常スコアは時間とともに減少した。提案手法のこれらの結果は従来手法によって計算された動作のばらつきの傾向とは一致しなかった。ただし、提案手法による異常スコアの傾向はいくつかの先行研究の結果と一致した。提案手法で計算した異常スコアを従来の特異スペクトル変換で計算した異常スコアと比較すると、提案手法の異常スコアは長期的な反復作業における人間の動きの全体的な傾向を反映できることが示唆された。また提案手法は、抽出された履歴行列が全体の動作の傾向から外れている場合に、他の動作区間の異常スコアが過剰に増加するような履歴行列を選択する上で生じうる問題による影響を受けないことが示唆された。

第6章 時系列データを対象とした異常検知手法を用いた作業動作評価： スパース構造学習による関節の協調関係の特徴の抽出に基づく 作業姿勢の経時変化の評価

6.1 緒論

第4章および第5章では時系列データに対応した異常検知手法の人間工学評価への有用性を実測したデータに基づいて検討した。第4章および第5章で用いた特異スペクトル変換とその拡張手法はいずれも単一の関節角度の観察のみを対象としていた。人間が多関節運動を実行する際に、冗長な自由度をいくつかの主要な協調関係に組織化する、関節の協調運動を実行することが知られている[177]。筋疲労が発生した際が多関節運動において、運動動員の変化と力および動作のばらつきが増加が筋疲労につながるという報告から、疲労を伴う状態での運動戦略は疲労の無い状態とは異なる可能性があることが報告されている[177][178][179][180][181]。したがって、反復作業中に作業者は個々の自由度の運動パターンを再編成する[182]か、異なる自由度を使用して作業を達成する[183]。単一の関節角度の観察だけでは検出することができず、複数の関節間の関係を考慮することで発見することが可能な時系列における作業姿勢の問題点が存在すると予想される。

関節間協調の従来の評価法として、動作中の関節の平均または最大値に焦点を当てる方法がある。しかし、この評価法は動きを生み出すための複数の関節がどのように調整されているかを定量化できない。そこで、協調構造の定量化や関節間の結合度合いの評価のために主成分分析[184]に基づく方法や関節角度間の相互相関の大きさに基づく評価[185]などが行われている。

人間の多関節運動の経時変化を多変量の変数で表現されるシステムであると仮定する場合、関節間協調は変数間の関係をグラフ構造として捉え、その構造を学習するスパース構造学習を用いて評価することが可能であると考えられる。スパース構造は古くは共分散構造選択の枠組みで行われてきた[123]が、計算コストの高さなどから実データへの応用が困難であった。近年、これらの問題点を解決したグラフィカル Lasso[125]というアルゴリズムによって、ノイズが多い実データなどへスパース構造学習を応用することが可能になり、近年活用用途が増加している。

本章では、複数の関節角度の関係を考慮した異常検知手法としてグラフィカル Lasso を用いた作業姿勢評価の有用性を明らかにすることを目的とする。具体的には、タスクや作業速度を変更した軽量物取り置き作業を実施し、作業姿勢を計測する。計測した作業姿勢データから、作業全体における主要な関節間協調をグラフィカル Lasso により推定する。さらに Ide et al.[122]が提案した相関異常度の計算に基づいて、作業中の経時的な関節間協調の変化に最も影響を与える関節角度の抽出および評価を行い、スパース構造学習の関節間協調および作業姿勢の経時変化の評価に対する有用性を評価する。

6.2 理論

6.2.1 グラフィカル Lasso

Ide et al.[122]は系が正常に稼働している場合、実験条件のばらつきに対して各変数の近傍グラフはほとんど不変であると仮定し、相関異常を検知する問題を各変数の近傍グラフの変化を定量的にとらえる問題と定義した。変数同士の関係をグラフとして表現するために、2つの変数の間の関係だけに着目するモデルが最も単純かつしばしば使用される。すなわち、「2つの変数が他のすべての変数を固定したときに条件付き独立である」ということと「2つの変数の間に辺がない」ことを同義にとらえ、確率分布からグラフを構築する。したがって、グラフ構造をデータから学習する問題（構造学習）がデータから確率分布を学習する問題に帰着される。多変量正規分布を仮定したグラフモデルをガウシアングラフィカルモデル（Gaussian Graphical Model, GGM）と呼ぶ。GGMにおける構造学習の問題は、共分散行列の逆行列で変数間の直接相関を表す精度行列を求める問題に帰着する。この際、主要な変数間の関係のみに着目するために、推定される精度行列はスパースな行列である必要がある。

M 次元の N 個の多変量正規観測値で構成されるデータ $\mathcal{D} = \{\mathbf{x}^{(n)} | n = 1, \dots, N\}$ があり、平均が0、分散が1になるように標準化されていると仮定する。 \mathcal{D} の標本共分散行列は次のように表される。

$$\mathbf{S}_{i,j} \equiv \frac{1}{N} \sum_{n=1}^N x_i^{(n)} x_j^{(n)} \quad (6.1)$$

ここで、 $\mathbf{S}_{i,j}$ は標準化前のデータ \mathcal{D} の相関係数行列と同じである。精度行列 $\mathbf{\Lambda}$ は共分散行列 \mathbf{S} の逆行列であるが、変数の数が10を超える場合、共分散行列が正則行列になることはほとんどなく、仮に共分散行列が正則になったとしても、精度行列が自動的にスパースな行列になることはほとんどない。したがって、精度行列を L_1 制約を課した最尤推定に基づく構造選択手法を用いて推定するために、Friedman et al.[125]によってグラフィカル Lasso（graphical lasso）が提案されている。具体的には、以下に示されるグラフィカル Lasso の手続きにしたがって、スパースな精度行列を学習する。

- ・ **初期化**：正則化項 ρ を設定する。データ \mathcal{D} を標準化後、式（6.1）を用いて精度行列の逆行列を共分散行列で初期化する。
- ・ **反復**：以下の処理を、 $i = 1, 2, \dots, M, 1, 2, \dots$ のように収束するまで繰り返す。
 - 1) 精度行列、精度行列の逆行列、および共分散行列について、以下の式のように i 番目の行と列を取り除き、新しい行列 \mathbf{L} , \mathbf{W} , および \mathbf{R} を作成する。

$$\mathbf{\Lambda} = \begin{pmatrix} \mathbf{L} & \mathbf{l} \\ \mathbf{l}^T & \lambda \end{pmatrix}, \mathbf{\Lambda}^{-1} = \begin{pmatrix} \mathbf{W} & \mathbf{w} \\ \mathbf{w}^T & \sigma \end{pmatrix}, \mathbf{S} = \begin{pmatrix} \mathbf{R} & \mathbf{s} \\ \mathbf{s}^T & s_{i,i} \end{pmatrix}. \quad (6.2)$$

2) 以下の Lasso 回帰の問題を解く.

$$\min_{\boldsymbol{\beta}} \left\{ \frac{1}{2} \left\| \mathbf{W}^{\frac{1}{2}} \boldsymbol{\beta} - \mathbf{b} \right\|^2 + \rho \|\boldsymbol{\beta}\|_1 \right\}. \quad (6.3)$$

3) $\boldsymbol{\Lambda}^{-1}$ の (i, i) 要素を式 (6.4) で計算された σ で置き換える. その他の i 番目の行と列の要素は, 式 (6.5) で計算された \mathbf{w} で置き換える.

$$\sigma = s_{i,i} + \rho, \quad (6.4)$$

$$\mathbf{w} = \mathbf{W}\boldsymbol{\beta}. \quad (6.5)$$

4) $\boldsymbol{\Lambda}$ の (i, i) 要素を式 (6.6) で計算された λ で置き換える. その他の i 番目の行と列の要素は, 式 (6.7) で計算された \mathbf{l} で置き換える.

$$\lambda = \frac{1}{\sigma - \mathbf{w}^T \mathbf{W}^{-1} \mathbf{w}} = \frac{1}{\sigma - \boldsymbol{\beta}^T \mathbf{W}^{-1} \boldsymbol{\beta}}, \quad (6.6)$$

$$\mathbf{l} = -\frac{\mathbf{W}^{-1} \mathbf{w}}{\sigma - \mathbf{w}^T \mathbf{W}^{-1} \mathbf{w}} = -\frac{\boldsymbol{\beta}}{\sigma - \boldsymbol{\beta}^T \mathbf{W}^{-1} \boldsymbol{\beta}}. \quad (6.7)$$

・ 収束した $\boldsymbol{\Lambda}$ と $\boldsymbol{\Lambda}^{-1}$ を出力する.

6.2.2 グラフィカル Lasso に基づく相関異常度の計算

グラフィカル Lasso を実行し, 2つのスパースな $\text{GGM} p_A(\mathbf{x})$ および $p_B(\mathbf{x})$ が得られたことに基づき個々の変数の異常度を計算していく. Ide et al.[122]は, 各変数がデータ \mathcal{D}_A と \mathcal{D}_B の違いにどの程度寄与するかを定量化する計算方法を提案した. 確率モデル $p_A(\mathbf{x})$ および $p_B(\mathbf{x})$ が与えられた時, 最も自然な違いの尺度は Kullback-Leibler 距離である.

$$d_i^{AB} \equiv \int d\mathbf{z}_i p_A(\mathbf{z}_i) \int dx_i p_A(x_i | \mathbf{z}_i) \ln \frac{p_A(x_i | \mathbf{z}_i)}{p_B(x_i | \mathbf{z}_i)}. \quad (6.8)$$

上式は, $p_A(x_i | \mathbf{z}_i)$ と $p_B(x_i | \mathbf{z}_i)$ の間の Kullback-Leibler 距離の期待値を, 分布 $p_A(\mathbf{z}_i)$ によって計算したものである. 式 (5.8) において, A と B を入れ替えることで d_i^{BA} の定義も得る. 式 (6.8) に現れる分布は正規分布のみであるためこの積分は解析的に実行され, 以下の式を得る.

$$d_i^{AB} = \mathbf{w}_A^T (\mathbf{l}_B - \mathbf{l}_A) + \frac{1}{2} \left\{ \frac{\mathbf{l}_B^T \mathbf{W}_A \mathbf{l}_B}{\lambda_B} - \frac{\mathbf{l}_A^T \mathbf{W}_A \mathbf{l}_A}{\lambda_A} \right\} + \frac{1}{2} \left\{ \ln \frac{\lambda_A}{\lambda_B} + \sigma_A (\lambda_B - \lambda_A) \right\} \quad (6.9)$$

ここで、 Λ_A およびその逆行列 Σ_A をそれぞれ次のよう分割した。

$$\Lambda_A = \begin{pmatrix} \mathbf{L}_A & \mathbf{l}_A \\ \mathbf{l}_A^T & \lambda_A \end{pmatrix}, \Sigma_A \equiv \Lambda_A^{-1} = \begin{pmatrix} \mathbf{W}_A & \mathbf{w}_A \\ \mathbf{w}_A^T & \sigma_A \end{pmatrix} \quad (6.10)$$

同様の分割は Λ_B および Σ_B にも適用される。 d_i^{BA} もまた、式 (6.9) の A と B を入れ替えることにより得られる。

GGM の定義から、 \mathbf{l}_A における非ゼロ要素の数は頂点 x_i の次数と同じである。したがって、第 1 項は主に近傍の生成および消滅に関する異常を検知する。第 2 項は、重み付きグラフとしての近傍グラフの「緊密さ」を表している。具体的に、仮に x_i が単一の辺を j に対して持つとすれば、この項は対応する相関関係の差を、単一の変数に対する精度 λ_A および λ_B で割ったものに比例する。第 3 項は各変数の精度もしくは分散の変化に結び付けられる。

d_i^{AB} および d_i^{BA} は、第 i 番目の頂点の周りの近傍グラフの変化を定量的に測る指標である。この値が大きければ大きいほど x_i が絡む変化は大きくなる。したがって、近傍保存の仮説を前提にすれば、第 i 変数の異常度は以下のように定義される。

$$a_i \equiv \max\{d_i^{AB}, d_i^{BA}\} \quad (6.11)$$

6.3 実験方法

6.3.1 被験者

被験者は 11 名の右利きの男性であった。被験者の年齢、身長、体重の平均±標準偏差は、23.1±1.5 歳、1732±42 mm、67.4±9.0 kg であった。また、被験者の手長、前腕長、上肢長は 185±11 mm、441±17 mm、740±27 mm であった。なお、本実験は首都大学東京日野キャンパスの研究安全倫理委員会の承認を得て実施した。実験を始める前に被験者に実験の概要を説明し書面による同意を得た。

6.3.2 実験条件

本研究では座位姿勢で 50 個の球状の軽量物（直径 35 mm、重さ 8 g）を各タスクおよび各作業速度条件で移動させる作業を実施した。タスク条件には、2 種類のタスク（タスク A およびタスク B）が含まれる。タスク A では、被験者は左側のカゴから右側のカゴへ軽量物を移動させた。一方タスク B では、被験者は奥に設置されたカゴから手前に設置されたカゴへ軽量物を移動させた。被験者は指定された作業ペース（指定条件）または主観的感覚に基づく作業ペース（主観条件）において、3 種類の作業速度条件（速い、普通、遅い）で軽量物取り置き作業を行うように指示された。表 6.3.1 は作業速度条件の仕様を示している。

被験者が座位姿勢で解剖学的基本姿勢を保持した状態で実験を開始した。解剖学的基本

姿勢を 5 秒間保持した後、被験者は事前に指示された作業速度で指定されたカゴへ軽量物を移動させることを要求された。指定条件の場合、被験者の作業ペースはメトロノームの音によって制御された。被験者は任意のメトロノームが鳴ったタイミングで作業を開始し、次のメトロノームの音が鳴るときに再び軽量物を取得するように指示された。ただし、被験者は軽量物の取り置きを連続して行う必要があり、次の軽量物を取るまでの間に休憩を挟まないよう指示された。主観条件の場合、被験者は自分のペースで作業を行う必要があったため、メトロノームの音が作業間隔に与える影響を排除するためにメトロノームの音は鳴らさなかった。指定条件と同様に、被験者は次の軽量物を取るまでの間に休憩を挟まないよう指示された。50 個の軽量物の取り置き作業終了後、被験者は再び 5 秒間解剖学的基本姿勢を保持し、1 条件終了となる。

表 6.3.1 作業速度条件

指定/主観	作業速度	仕様
指定	速い	タスク間隔が 1 秒
	普通	タスク間隔が 1.5 秒
	遅い	タスク間隔が 2 秒
主観	速い	作業ミスを気にすることなく作業できる最大速度で作業を実施
	普通	被験者が最も作業しやすい速度で作業を実施
	遅い	絶対に作業ミスを起こさない程度の速度で作業を実施

6.3.3 測定項目と解析方法

6.3.3.1 作業姿勢計測

磁気式動作計測装置 (trakSTAR, Ascension Technology Corp.) を用いて、腰部、胸部、右上腕、右前腕、右手の 3 次元位置と方位をサンプリング周波数 50 Hz で取得した。各身体セグメントのレシーバの位置は先行研究[150]を参考に配置した。

各身体セグメントの傾きを 3 次元剛体リンクモデルに当てはめることによって体幹部および右上肢の解剖学的関節角度 (体幹前傾角, 体幹右傾角, 体幹左旋角, 肩関節外転角, 肩関節屈曲角, 肩関節内旋角, 肘関節屈曲角, 前腕回内角, 手関節撓屈角, 手関節掌屈角) について算出した。

6.3.3.2 グラフィカル Lasso による主要な関節の協調関係の抽出

実験条件による主要な関節の協調関係の変化を明らかにするために、グラフィカル Lasso を各実験条件における全体のデータに対して適用し、精度行列を推定した。その際の正則化係数 ρ は 0.6 に設定した。また、各実験条件のデータ全体より計算された標本共分散行列の各要素の絶対値を計算した。その後、被験者 11 名分の標本共分散行列と精度行列の各要素の中央値を計算した。

6.3.3.3 異常スコアの経時変化

本研究では、関節の協調関係の変化を考慮した作業姿勢の経時変化を評価するために、作業開始時点に対する各時刻の作業姿勢の変化を比較した。具体的には、長さ 250 フレームのスライド窓を用いて一連の作業姿勢データを部分時系列へと変換する。最初の部分時系列を比較対象のデータとし、全ての部分時系列について異常スコアを実験条件ごとに計算する。その後、被験者 11 名分の各時刻における異常スコアの中央値を計算した。さらに、計算された各時刻における異常スコアの中央値を平滑化係数 0.01 を用いた指数平滑化法を用いて平滑化した。

6.4 結果

6.4.1 グラフィカル Lasso による主要な関節間協調の抽出

図 6.4.1 および図 6.4.2 にそれぞれ標本共分散行列の絶対値およびグラフィカル Lasso で推定された精度行列のヒートマップを示す。図 6.4.2 の精度行列のヒートマップの対角要素は、変数の自己相関を示すため、他の要素よりも値が非常に大きくなる。ヒートマップのスケールが自己相関の大きさに従う場合、変数間の直接相関の値が検討しづらくなるため、推定された精度行列の対角要素を 0 に置き換えた行列を用いて精度行列のヒートマップを作成した。精度行列のヒートマップの結果から、グラフィカル Lasso によって推定された精度行列は標本共分散行列のヒートマップと比較して、主要な関節間協調を抽出できていることが示された。タスク A では、体幹右傾角と前腕回内角の組み合わせの直接相関が指定または主観条件に関係なく速い作業速度条件で最も大きかった。通常または遅い作業速度条件の場合、肩関節屈曲角と肩関節内旋角の組み合わせの直接相関が最も大きかった。タスク B では、全ての実験条件において肩関節外転角と肘関節屈曲角の組み合わせの直接相関が最も大きかった。

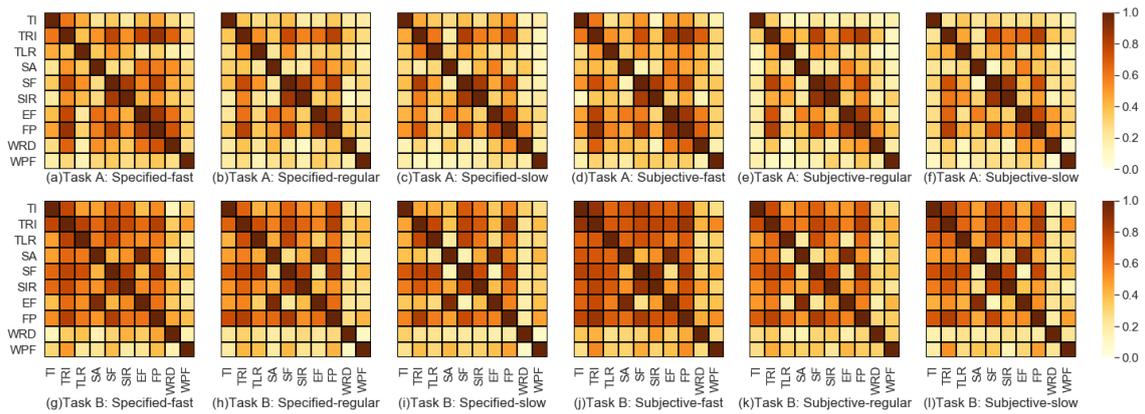


図 6.4.1 標本共分散行列の絶対値のヒートマップ ※図中の略字の定義を以下に示す。

TI : 体幹前傾角, TRI : 体幹右傾角, TLR : 体幹左旋角, SA : 肩関節外転角,
 SF : 肩関節屈曲角, SIR : 肩関節内旋角, EF : 肘関節屈曲角, FP : 前腕回内角,
 WRD : 手関節撓屈角, WPF : 手関節掌屈角

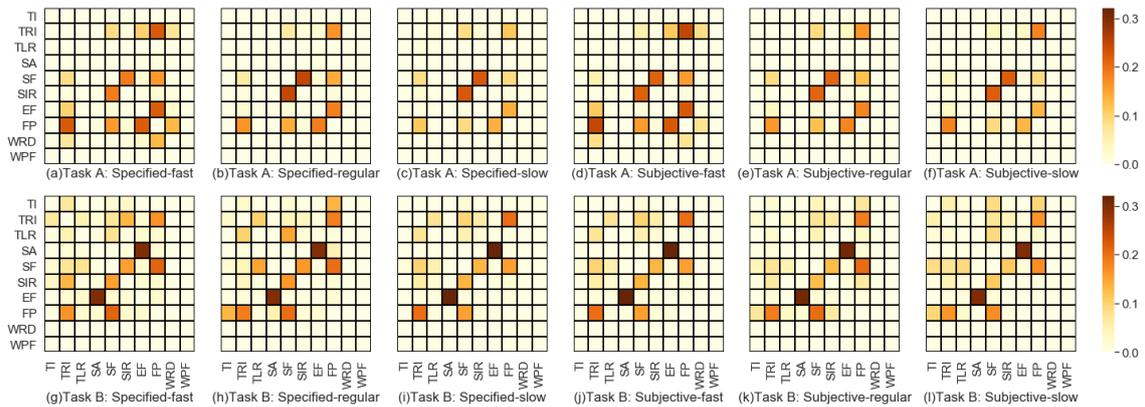


図 6.4.2 推定された精度行列のヒートマップ ※図中の略字の定義を以下に示す。

TI : 体幹前傾角, TRI : 体幹右傾角, TLR : 体幹左旋角, SA : 肩関節外転角,
 SF : 肩関節屈曲角, SIR : 肩関節内旋角, EF : 肘関節屈曲角, FP : 前腕回内角,
 WRD : 手関節撓屈角, WPF : 手関節掌屈角

6.4.2 異常スコアの経時変化

図 6.4.3 にタスク A の各関節角度の異常スコアの経時変化を示す。指定・速い条件を除いて全ての条件で、肘関節屈曲角の異常スコアの最終値が他の関節と比較して最も大きかった。指定・速い条件では、手関節撓屈角の異常スコアの最終値が最も大きかった。全ての条件で体幹右傾角の異常スコアの最終値が最小であった。指定・速い条件と主観条件の各速度条件において、体幹前傾角の異常スコアの最終値は 2 番目に小さかったが、指定・普通および遅い条件では異なる傾向が得られた。

図 6.4.4 にタスク B の各関節角度の異常スコアの経時変化を示す。全ての条件において、前腕回内角の異常スコアの最終値が他の関節と比較して最も大きかった。

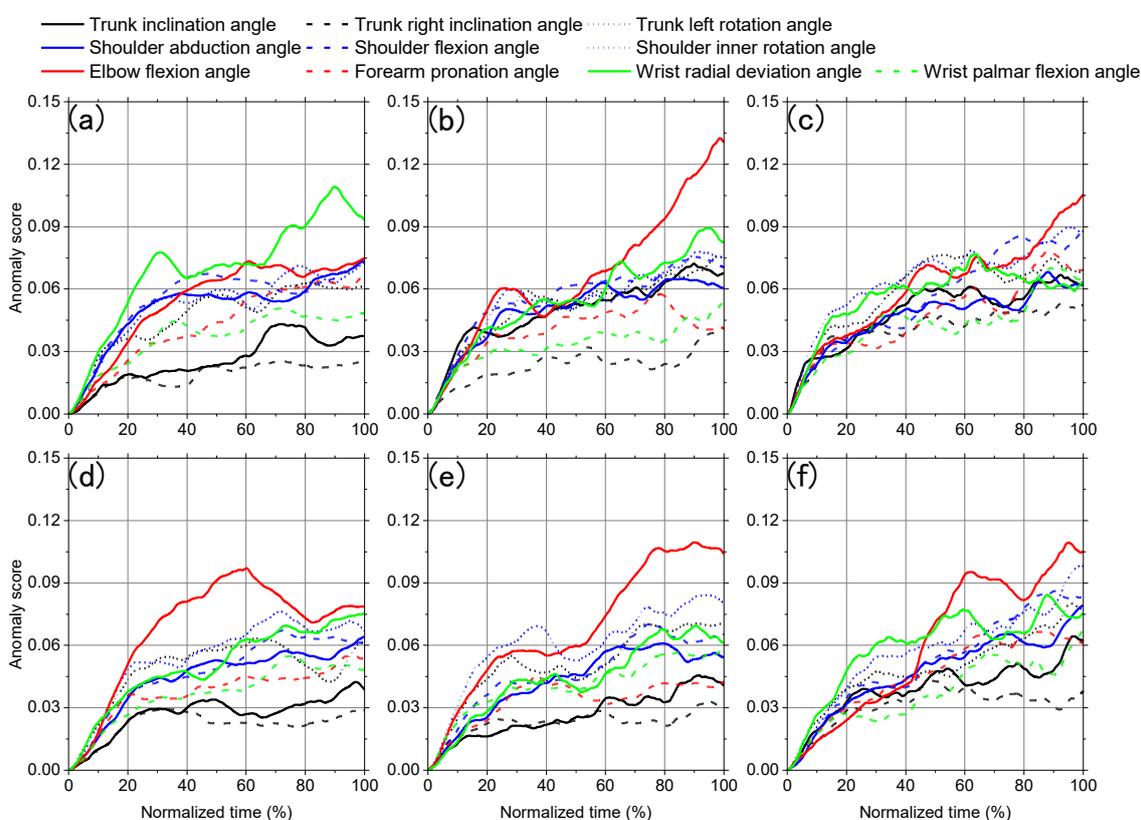


図 6.4.3 タスク A の各関節角度の異常スコアの経時変化：
 (a)指定・速い条件, (b)指定・普通条件, (c)指定・遅い条件,
 (d)主観・速い条件, (e)主観・普通条件, (f)主観・遅い条件

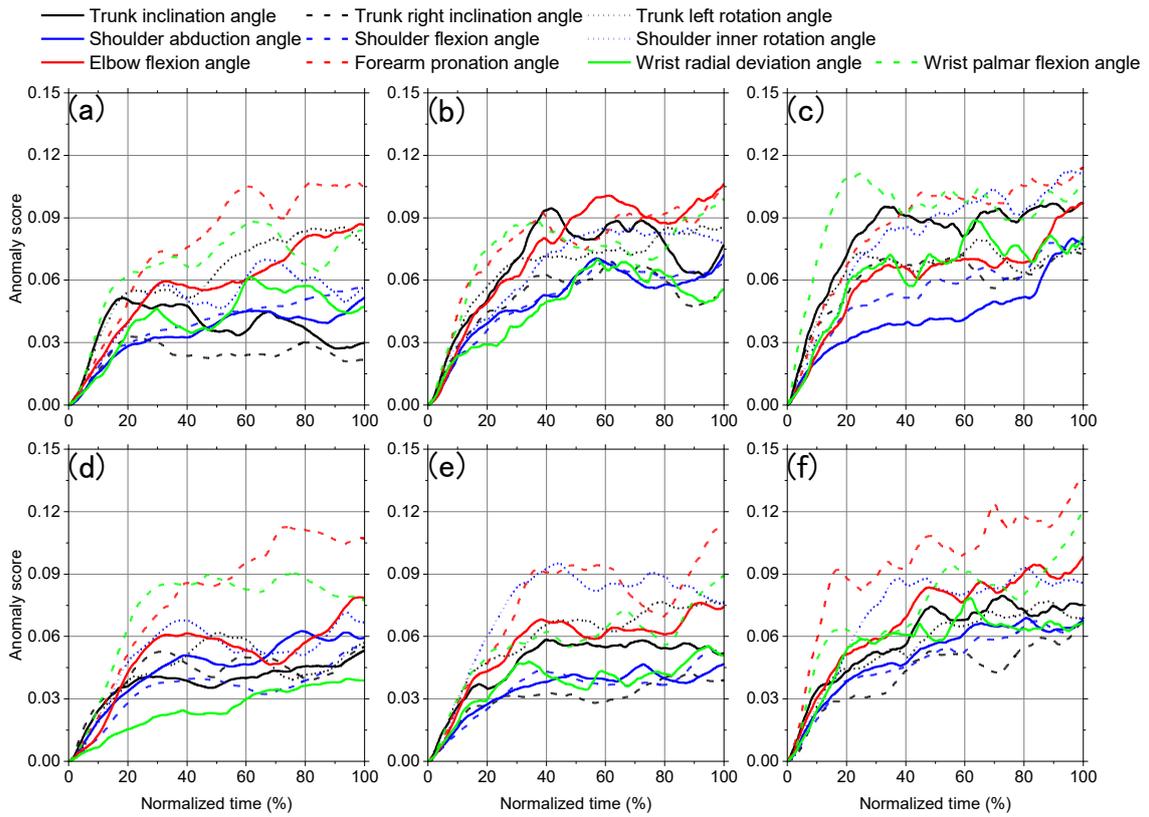


図 6.4.4 タスク B の各関節角度の異常スコアの経時変化：
 (a)指定・速い条件, (b)指定・普通条件, (c)指定・遅い条件,
 (d)主観・速い条件, (e)主観・普通条件, (f)主観・遅い条件

6.4.3 タスク A の肘関節屈曲角のそれぞれの異常スコアの傾向

図 6.4.5 にタスク A の肘関節屈曲角のそれぞれの異常スコアの経時変化を示す。(a)の結果より、指定および主観に関わらず、速い条件における異常スコアの最終値が他の速度条件と比較して小さかった。(b)近傍の生成および消滅と(d)変数自体の分散は、(a)と非常に似た傾向を示した。一方、(c)緊密さは他の異常スコアの傾向との類似性は確認されなかった。

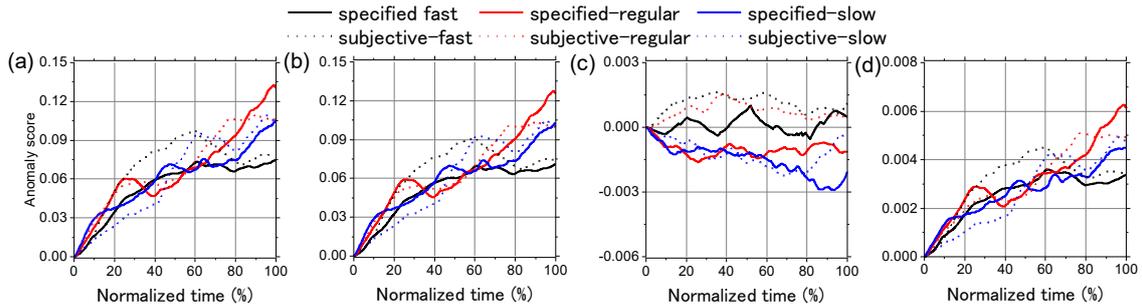


図 6.4.5 タスク A の肘関節屈曲角のそれぞれの異常スコアの経時変化
(a)異常スコア a_i , (b)近傍の生成及び消滅, (c)緊密さ, (d)変数自体の分散

6.4.4 タスク B の前腕回内角のそれぞれの異常スコアの傾向

図 6.4.6 にタスク B の前腕回内角のそれぞれの異常スコアの経時変化を示す。(a)の結果より、指定および主観に関わらず、速い条件における異常スコアの最終値が他の速度条件と比較して小さかった。(b)近傍の生成および消滅は、(a)と非常に似た傾向を示した。一方、(c)緊密さとは他の異常スコアの傾向との類似性は確認されず、(d)の変数自体の分散も、特に標準化時刻 60%以降において、(a)との類似度は小さかった。

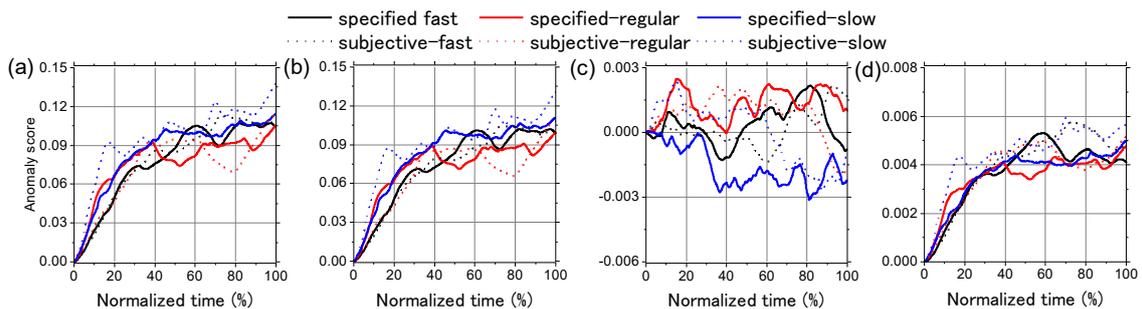


図 6.4.6 タスク B の前腕回内角のそれぞれの異常スコアの経時変化
(a)異常スコア a_i , (b)近傍の生成及び消滅, (c)緊密さ, (d)変数自体の分散

6.5 考察

タスク A では、速い速度条件では体幹右傾角と前腕回内角の組み合わせの直接相関が最も大きく、普通または遅い条件では肩関節屈曲角と肩関節内旋角の組み合わせの直接相関が最も大きかった。タスク B では全ての実験条件で、肩関節外転角と肘関節屈曲角の組み合わせの直接相関が最も大きかった。タスク A では被験者は身体の正中線を横切ってリーチ姿勢を形成する必要があったため、タスク中に肘関節が体幹部に触れないように肩関節屈曲角を変化させ右上肢を挙上させた姿勢を形成した。その後、左に設置されたカゴへリーチするために肩関節を内旋させた。タスク A での普通および遅い条件での直接相関の結果は被験者が上述の動作戦略を採用したことを示唆している。一方で、速い条件において体幹右傾角と前腕回内角の直接相関が増加したことは被験者がより素早くカゴへリーチするために異なる動作戦略を採用したことを示唆している。具体的には、右上肢の移動距離を短くするために、被験者は体幹部を右に傾けてリーチ姿勢を形成した。したがって、速い作業速度条件における直接相関の結果は上記の動作戦略を採用し、リーチ動作中に付随して前腕の回内が発生することによって体幹右傾角と前腕回内角の直接相関が増加することを示唆している。タスク B では被験者は軽量物を奥に配置されたカゴから手前のカゴへ移動させるよう指示された。Yang et al.[159]は遠距離と近距離に設置された目標に対する反復的なポイントングタスク中に肩関節の外転と肘関節の屈曲が同相で変化することを報告した。この研究のタスク B における主要な関節間協調の抽出結果は Yang et al.[159]の研究結果と一致している。タスク A とタスク B での主要な関節間協調の抽出の結果は、グラフィカル Lasso がタスク全体での人間の動作から特徴的な関節間協調を抽出する上で有用な手法であることを示唆している。

タスク A では肘関節屈曲角の異常スコアの最終値が、指定・速い条件を除く全ての実験条件において他の関節角度の異常スコアの最終値よりも大きかった。この結果は、ほとんどの実験条件において肘関節屈曲角の変化がタスク開始時と終了時の関節間協調の違いに寄与していることを示唆している。同様にタスク B では、前腕回内角の異常スコアの最終値が全ての実験条件において他の関節角度よりも大きく、前腕回内角の変化がタスク開始時と終了時の関節間協調の違いに寄与していることを示唆している。図 6.4.5(a)および図 6.4.6(a)に示すタスク A の肘関節屈曲角およびタスク B の前腕回内角の最終的な異常スコアは速い速度条件が最も小さかった。Srinivasan et al.[172]は反復作業中の作業ペースの増加に伴い動作のばらつきが減少することを報告した。そのため、軽量物の反復的な取り置き作業において作業ペースが増加することによって動作のばらつきが減少し、作業開始時と作業終了時の作業姿勢や動きの差が小さくなったため、速い作業速度条件における異常スコアの最終値が他の作業速度条件よりも小さくなった。ただし、特に指定条件において遅い作業速度での肘関節屈曲角の最終値は通常の作業速度よりも小さかった。被験者にとって作業しやすい速度において、被験者は作業姿勢を変化させることが容易になり、動作のばらつきが増加したが、速度を強制されるような作業条件において動作のばらつきが低下すること

を示唆している。

また、タスク A の肘関節屈曲角の異常スコアの経時変化において、(a)異常スコアと(b)近傍の生成および消滅と(d)変数自体の分散に関する項の傾向が類似していた。これは、タスク A において肘関節が能動的に変化し、作業開始時と作業終了時の関節間協調の違いに影響を与えたことを示唆している。一方で、タスク B の前腕回内角の異常スコアの経時変化において(a)異常スコアと(b)近傍の生成および消滅の変化は同様の变化傾向を示した。ただし、(d)変数自体の分散に関する項は、特に標準化時刻 60%以降において(a)異常スコアとは異なる傾向を示した。このことから、タスク B の前腕回内角は作業開始時と作業終了時の関節間協調の差に最も寄与しているが、他の関節との関係の変化による影響が大きく、他の関節の変化に合わせて受動的に変化している可能性があることを示唆している。これらの知見から、単純に総合した異常スコアを確認することで関節間協調の変化に影響を与える関節の抽出が可能であることが示唆された。さらに、異常スコア計算における各項の経時変化を分析することで、能動的に変化した関節か受動的に変化した関節か判断することができる可能性が示唆された。

6.6 小括

本研究では、タスクや作業速度条件を変更した反復的な軽量物取り置き作業において、関節間協調および作業姿勢の経時変化の評価に対するグラフィカル Lasso の有用性を検証した。グラフィカル Lasso により推定された精度行列は、標本共分散行列と比較して主要な関節間協調を抽出できることに加えて、タスク条件による動作戦略の違いを反映した特徴的な関節角度のペアを抽出することができることが示唆された。また、作業開始時と終了時の関節間協調の違いに最も寄与する関節角度は異常スコアの経時変化に基づき特定された。さらに、異常スコア計算における各項の経時変化の分析は、関節間協調にある関節角度が能動的または受動的に影響を与えるかについて判断できる可能性を示唆した。

第7章 結論

7.1 結論

本論文では、第1章で研究背景として昨今の人間の作業形態の変化、人間工学作業評価法の概要と問題点、機械学習・コンピュータビジョン分野の発展と人間工学応用、異常検知手法の概要についてまとめ、研究目的について述べた。

第2章および第3章は、平均値などの作業姿勢の代表値が収集された場面における作業姿勢の問題の発見のために、外れ値検知手法の1つである **One-Class Support Vector Machine** による異常姿勢抽出を行い、従来の人間工学評価との関連を評価した。第2章では作業域が制限され、関節角度や関節トルク比の変化は小さいものの主観的な作業性には大きな影響を与えるような作業の一例である身体近傍のねじ締め作業を対象に **One-Class Support Vector Machine** の有用性を評価した。その結果、作業のしにくい条件かつ RULA や LUBA などにより負担が高い条件で異常率が増加することに加え、作業はしにくい関節角度は作業しやすい条件と近い傾向にあるような条件においても異常率が増加した。このことから、**One-Class Support Vector Machine** による異常姿勢の検出が作業の評価へ応用可能であることを示唆する結果を得た。第3章では、保守点検作業等において障害物を回避しながら作業する場面のように負荷の大きな姿勢保持が強制されるような場面における **One-Class Support Vector Machine** の有用性を評価した。結果として、ほとんど全ての条件で実験条件で障害物幅の増加に伴い右上肢と頭頸部の作業姿勢の異常率が増加し、**One-Class Support Vector Machine** を使用して右上肢および頭頸部の作業姿勢の違いを検出し、様々な条件において障害物幅の影響を評価できることを示唆する結果を得た。

第4章では、作業中に突発的に発生するミスなどによる姿勢変化を変化点検知手法の1つである特異スペクトル変換を応用することで検出可能か検討した。突発的な姿勢変化を再現するために作業間隔が突発的に減少する作業を行い、計測された作業姿勢の時系列データに対して特異スペクトル変換を適用し、突発的な作業姿勢を異常スコアの変化として捉えることができるか検討した。また、特異スペクトル変換のパラメータの1つであるラグが異常姿勢の検出に与える影響について検討した。結果として、突発的な姿勢変化を誘発した条件の異常スコアの平均値は通常の作業条件よりも大きく、作業全体の姿勢変化を検出できることが示唆された。また、ラグの値は作業周期と対応する必要があることが示された。

第5章では、反復作業中の人間の動作のより長期的な動作履歴を考慮した特異スペクトル変換に基づく異常スコアの新しい計算法を提案した。提案手法の有用性を従来手法で計算された動作のばらつきと従来の特異スペクトル変換で計算された異常スコアと比較することで明らかにした。提案手法を用いて異常スコアを計算した場合、従来手法で計算された動作の傾向とは一致しなかったがいくつかの先行研究の知見と一致し、提案手法の有用性が示された。提案手法で計算した異常スコアを従来の特異スペクトル変換で計算した異常スコアと比較すると、提案手法の異常スコアは長期的な反復作業における人間の動きの全

体的な傾向を反映できることが示唆された。また提案手法は、抽出された履歴行列が全体の動作の傾向から外れている時に他の動作区間の異常スコアが過剰に増加するような履歴行列を選択する上で生じうる問題による影響を受けないことが示唆された。

第 6 章では、タスクや作業速度条件を変更した軽量物取り置き作業においてスパース構造学習の関節間協調および作業姿勢の経時変化の評価に対する有用性を検証した。結果として、グラフィカル Lasso による主要な関節間協調の抽出は標本共分散行列のヒートマップと比較して、主要な関節の抽出が可能であることを示し、タスク条件による動作戦略の違いを反映した特徴的な相関のある関節のペアを抽出できることが示された。また、異常スコアの経時変化を計算することで、作業開始時作業終了時の間の関節間協調の違いに最も寄与する関節角度を異常スコアの増加という観点で示すことができた。さらに、異常スコア計算における各項の影響を詳細に分析することによって、その関節角度が関節間協調に能動的または受動的に影響を与えるかを判断することができる可能性を示唆する結果を得た。

第 2 章と第 3 章と総括すると、One-Class Support Vector Machine は、作業内容や作業環境によって作業姿勢が制限されるような作業や低負荷作業において、作業条件間や被験者間の作業姿勢の比較を行う場合、異なる傾向を示す作業姿勢を異常姿勢として検出できることを示した。この手法は、作業姿勢の代表値を対象としていることから、従来の人間工学評価との関係が議論しやすいという利点がある。加えて、従来の人間工学評価では発見が困難な傾向の検出を補助することができることから、作業者にとって快適な作業環境設計や人が操作しやすい製品・機器の使用環境設計へ応用することに期待がかけられるとされる。

第 4 章では特異スペクトル変換を用いて、異常な動作を含む作業と正常な作業の作業間の違いを異常スコアの平均値またはしきい値を超えた異常スコアの数で評価できることを示した。突発的な変化の検出のために特異スペクトル変換が応用できることが示されたことから、筋電図や操作力の信号などの突発的な変化の検出へ応用することに期待がかけられるとされる。特に操作力などは、機器の操作性の評価や作業中の予期せぬ力の発揮や反力の減少などによる危険行動の予測のためにも十分に応用できると考えられる。

第 5 章では、より長期的な人間の動作履歴を考慮した特異スペクトル変換ベースの異常スコアの計算方法を提案し、動作のばらつきの経時変化を推定できることを示した。本提案手法により、動作のばらつきの経時変化を推定できることから、他の筋電図や操作力などの信号のばらつきの評価に関しても応用することが可能であると考えられる。本提案手法は特異スペクトル変換に基づいているため、特異値分解を用いて主要な信号の成分を抜き出し、比較を行うため、操作力や筋電図などのノイズの影響を受けやすい評価指標に対しても主要な成分のみでばらつきの傾向を判断することができると考えられる。

第 6 章ではグラフィカル Lasso を用いて、作業による関節間協調の違いの評価と関節間協調の変化に影響を与える関節の特定ができることを示した。本手法を用いることで、ノイズの多い実測データの中から主要な関係を抽出できることから、筋電図と関節角度の関係の

評価や、操作力と筋電図の関係などの評価へ応用することに期待がかけられる。従来法では、平均値などの代表値の増減傾向から関係の有無を判断していた指標を、時系列データ同士を比較して、同様の变化傾向にあるのか明らかにすることができると考えられる。

本研究では、静止姿勢データに対しては **One-Class Support Vector Machine**、時系列データに対しては特異スペクトル変換およびグラフィカル **Lasso** といった手法をそれぞれ独立して使用したが、これらの手法を組み合わせた異常検知も作業姿勢・動作の問題点の検出のために有用であると考えられる。例えば、特異スペクトル変換により異常スコアの増加が見られた時刻の作業姿勢のみを抽出し、**One-Class Support Vector Machine** により分類することで、時系列中に真に問題である作業姿勢の変化が発生した時刻の特定が可能になると考えられる。また、特異スペクトル変換は本来変化点を検出するための手法であるため、計算に用いるパラメータ次第では、連続して測定したデータの中から代表値となりうる作業姿勢を取っている区間を抽出し、**One-Class Support Vector Machine** へ適用することが可能になる。この一連の流れが確立することに加え、ビデオカメラから作業姿勢を推定する技術の発展も合わせることによって、作業の様子をビデオカメラでモニタリングしながら、代表となる作業姿勢をサンプリングし、作業中の姿勢の問題点を検出することが可能になると考えられる。グラフィカル **Lasso** に基づいた異常スコアの計算は、関節間協調の変化に各関節角度が与える影響度合いを示しているため、影響度合いの大きい関節角度の時系列データに対して、特異スペクトル変換を適用することで、異常スコアの増減という観点から、関節間協調の変化に影響を与えた関節の挙動の特定などが可能になると考えられる。

以上より、本研究では、自動化が進む現在の生産現場において依然として人間の手作業で行われる低負荷・高反復作業やメンテナンス作業を含む非定常作業の作業姿勢評価に関して、異常検知手法を用いることで以下の知見を得た。それらの知見を踏まえて、本研究では異常検知手法の作業姿勢評価への適用可能性を明らかにしたと結論付ける。

- ① 静止姿勢を対象とした作業姿勢評価において **One-Class Support Vector Machine** を応用することで、把握が困難であった姿勢の違いが検出可能である。
- ② 特異スペクトル変換を応用することで、突発的要因によって誘発される作業全体の姿勢および動作の変化を検出可能である。
- ③ 特異スペクトル変換の応用に加えて、長期的な反復作業における経時的な姿勢変化の評価を行う場面においては、提案手法を用いることで動作のばらつきの経時変化が推定可能である。
- ④ グラフィカル **Lasso** およびグラフィカル **Lasso** に基づく異常スコアの計算は、主要な関節間協調の抽出と反復作業における関節間協調を考慮した作業姿勢の変化に寄与する関節の特定が可能である。

7.2 今後の展望

本節では、異常検知手法を実際に作業評価へ応用する上で必要となる技術的課題と本研究の今後の発展性について述べる。

- ・ 身体負担の考慮

作業姿勢や動作に加えて身体負担を考慮した異常検知手法を行うことは、作業者によって快適な作業環境設計において、作業姿勢や動作だけでは判定できない問題となる作業姿勢を検出し、評価することが可能になる。身体負担を考慮することによって、第3章で示されたような、関節トルク比などの身体負担が高い作業姿勢であっても、その姿勢の傾向が大部分の作業姿勢と一致している場合に異常姿勢として検出することが困難であるという課題点を解決することができる。他の例として、特異スペクトル変換による突発的な姿勢変化の検出において身体負担を考慮することで、作業姿勢の変化による通常とは異なる身体負担の増加を検出し、作業姿勢変化との関係から作業中に発生した問題のリスク評価などが可能になると考えられる。

- ・ 異常スコアを識別するしきい値の拡充

第1章の異常検知の概要で述べたように異常検知手法による出力はスコアとラベルに大別され、スコアによる出力の場合、スコアの高いものを評価するか、ある基準のしきい値を設け、その値を上回るデータについて分析することが求められる。このしきい値を従来の人間工学評価法による作業姿勢評価結果や筋疲労評価と関連付けて定義することで、人間工学的な作業姿勢および身体負担の問題を反映した異常検知を行えるようになると考えられる。例えば、第5章の特異スペクトル変換に基づく動作のばらつきの経時変化と従来の筋疲労評価手法との関係を明らかにすることで、作業者の疲労状態のモニタリングが可能になり、疲労状態に応じた休憩指示や作業の変更などが可能になる。また、第6章で実施したスパース構造学習に基づく相関異常の経時変化についても、筋疲労との関係を明らかにすることによって、作業者の疲労が関節間協調の変化に与える影響や、作業者の疲労に応じた動作戦略の評価へとつながると考えられる。

- ・ 異常検知手法に関連するパラメータの影響の検討

それぞれの異常検知手法における各パラメータの影響を検討することは、作業姿勢や動作の問題点の検出のために重要である。第2章および第3章で用いた **One-Class Support Vector Machine** の場合、本研究で用いたガウシアンカーネルには外れ値の上限を決める ν というパラメータ以外に、決定境界の滑らかさを制御するパラメータである σ が存在する。本研究では、 σ の値は入力データに対して適切なスケール係数を自動計算する関数の機能を用いたが、 σ の値を変更することにより測定データのノイズの影響を調整する。今後、マーカレスのキャプチャシステムなど現在のモーションキャプチャシステムより測定精度の劣る

作業姿勢計測手法に対して **One-Class Support Vector Machine** による評価を適用する場合には、測定誤差や精度良く計測できなかった作業姿勢の影響を排除するために、 σ の値を調整する必要がある。また、第4章では、特異スペクトル変換のパラメータの1つであるラグに着目し、作業姿勢および作業動作の問題点に与える影響について検討した。現在ではラグは非負定数として定められているため、異常スコアの計算過程において、動的にラグを変更しながら作業姿勢や動作の異常を検出することが今後の課題となる。動的にラグを変更しながら作業姿勢や動作の異常の検出を行うことが可能になれば、作業中の周期の変化による異常スコアの増加を抑制し、作業姿勢変化の問題を正確にとらえることが可能になる。さらに、複数の周期の異なる作業を連続して実施した作業においても、異なる作業間での異常スコアの増加を抑え、作業内での姿勢や動作の突発的な変化を検出することが可能になると考えられる。また、特異スペクトル変換の他のパラメータも異常スコアに対する感度を変更することが可能であることから、より短い時間で発生する作業姿勢や動作の異常を検出することが可能になると考えられる。

・ 計算コストの削減

第4章および第5章で用いた特異スペクトル変換は特に計算に時間がかかる手法であった。第4章の全データの解析には約24時間、第5章の全データの解析には最大で72時間程度の計算時間を要した。特異スペクトル変換の計算コストの高さの要因は、特異値分解という重い演算を反復的に実施することが原因であると言及されており、対称行列を三重対角するランチョス法などを用いて、一部の特異値分解を省略し、計算効率を上げるためのアルゴリズムも提案されている。今後、より高速な計算が可能になることによって、作業者の姿勢や動作のリアルタイムでの評価が可能になる。リアルタイムでの評価の実施は、作業ミスの発生を即時検出することによって不良品の発生を予測することによる生産性の向上や、危険な行動の検出および予測による事故の発生の予防などへ発展することに期待がかけられるとされる。

・ 作業条件の拡充

本研究にて用いた異常検知手法および提案手法を実作業へ応用していくために、より広範な作業条件へと適用していくことが望まれる。本研究では比較的単純な作業条件において異常検知手法の有用性を明らかにしたため、実際に存在する作業を異常検知手法で評価することができるか追加で検討していくことが期待される。実際の作業現場では計測できるデータが今よりも限られる可能性がある。例えば実作業の場合、本研究で用いた光学式のモーションキャプチャシステムを導入することは困難であり、より簡便な手法で作業姿勢を計測する必要がある。そのため、本研究で検出できた精度で作業の異常を検出できるかなどを追加で検討していくことで、より実作業への応用に適した異常検知手法の構築・選定が可能になると考えられる。また、1人の作業者が複数のタスクを連続して実施する作業は昨

今の作業現場でも実施されている。このような作業では、タスクの切り替わりを第4章で用いた特異スペクトル変換を用いて認識し、その作業条件における作業姿勢の代表値を **One-Class Support Vector Machine** で解析するなど、本研究で用いた異常検知手法を組み合わせることで作業姿勢の問題点検出の有用性の評価を行っていくことが重要であると考えられる。

- ・ マーカレスキャプチャシステムとの連携

本研究で提案された異常検知手法を用いた人間工学評価法をより広範な作業場面へと適用していくためには、専門の機器を使用することなく作業姿勢および動作を計測するシステムとの連携が必要不可欠である。近年は **OpenPose** のようなビデオカメラ映像から作業姿勢を検出する手法がいくつか開発されている。今後はそれらの手法で計測されたデータから作業姿勢や動作の問題を検出できるようにするための追加の検討が必要である。**OpenPose** は映像内の人間の各関節の2次元位置情報を出力するため、その値から3次元の関節の位置情報へ変換し、剛体リンクモデルに当てはめ、関節角度やセグメントの角度を推定する一連のシステムを経て、異常検知手法へ適用する。または2次元の位置情報のみから異常検知手法を用いて作業姿勢の問題を検出する手続きを構築し、それをモーションキャプチャシステムで計測された同様の作業姿勢の異常検知結果と比較し、その推定精度を高めていく方法が考えられる。

- ・ 作業員個人の特性の考慮

作業員毎に快適な作業環境を設計するためには、作業員の個人特性（年齢、身長、体重など）を考慮した異常検知手法の構築が必要である。作業員の個人特性を考慮するためには、異なる身体特性を持つ被験者を複数人用意し、各身体特性群における作業姿勢や身体負担のデータの取得が必要になる。しかし現実的に身体特性の異なる複数の被験者群を用意することは困難であるため、デジタルヒューマンなどによる作業姿勢の生成アルゴリズムとの組み合わせが考えられる。デジタルヒューマン上で被験者の身体特性を考慮して作業姿勢を生成し、その姿勢を代表値として定義し、作業姿勢に一定のばらつきを持たせた分布を作成する。このような作業員の代表値となる作業姿勢が生成可能になることは、異常検知手法を用いた作業姿勢評価において正解となる教師データが利用可能になることと同義である。明確な基準が定義された異常検知手法の適用が可能になることによって、正確な作業姿勢や動作、または身体負担の問題点の検出が可能になると考えられる。

参考文献

- [1] Kadir, B.A., Broberg, O., & da Conceição, C.S. (2019). Current research and future perspectives on human factors and ergonomics in Industry 4.0. *Computers & Industrial Engineering*, 137, 106004.
- [2] Forsman, M., Hasson, G.Å., Medbo, L., Asterland, P., & Engström, T. (2002). A method for evaluation of manual work using synchronized video recordings and physiological measurements. *Applied Ergonomics*, 33, 533-540.
- [3] Fantini, P., Tavola, G., Taisch, M., Barbosa, J., Leitao, P., Liu, Y., ... Lohse, N. (2016). Exploring the integration of the human as a flexibility factor in CPS enabled manufacturing environments: Methodology and results. *IECON 2016 – 42nd annual conference of the IEEE industrial electronics society* (pp. 5711-5716). IEEE.
- [4] Richert, A., Shehadeh, M. A., Müller, S. L., Schröder, S., & Jeschke, S. (2016). Socializing with robots: Human-robot interactions within a virtual environment. *2016 IEEE workshop on advanced robotics and its social impacts (ARSO)* (Vol. November, pp. 49-54). IEEE.
- [5] Romero, D., Stahre, J., Wuest, T., Noran, O., Bernus, P., Fast-Berglund, Å., & Gorecky, D. (2016). Towards an Operator 4.0 Typology: A human-centric perspective on the fourth industrial revolution technologies. *CIE 2016: 46th international conferences on computers and industrial engineering* 0-11.
- [6] Mathiassen, S.E. (2006). Diversity and variation in biomechanical exposure: What is it, and why would we like to know? *Applied Ergonomics*, 37(4), 419-427.
- [7] Ishihara, S., Ishihara, K., Nagamachi, M., & Matsubara, Y. (1995). An automatic builder for a Kansei Engineering expert system using self-organizing neural networks, *International Journal of Industrial Ergonomics*, 15, 13-24.
- [8] Kolich, M., Seal, N., & Taboun, S. (2004). Automobile seat comfort prediction: statistical model vs. neural network. *Applied Ergonomics*, 35, 275-284.
- [9] Bataineh, M., Marler, T., Abdel-Malek, K., & Arora, J. (2016). Neural network for dynamic human motion prediction. *Expert Systems With Applications*, 48, 26-34.
- [10] Varrecchia, T., De Marchis, C., Rinaldi, M., Draicchio, F., Serrao, M., Schmid, M., Conforto, S., & Ranavolo, A. (2018). Lifting activity assessment using surface electromyographic features and neural networks. *International Journal of Industrial Ergonomics*, 66, 1-9.
- [11] Abobakr, A., Nahavandi, D., Hossny, M., Iskander, J., Attia, M., Nahavandi, S., & Smets, M. (2019). RGB-D ergonomic assessment system of adopted working postures. *Applied Ergonomics*, 80, 75-88.
- [12] 瀬尾明彦 (2005). 作業関連性筋骨格系障害に関わる計測と評価の手法. *労働科学*, 81(1), 6-15.
- [13] David, G.C. (2005). Ergonomics methods for assessing exposure to risk factors for work-related musculoskeletal disorders. *Occupational Medicine*, 55, 190-199.

- [14] Karhu, O., Kansil, P., & Kuorinka, I. (1977). Correcting working posture in industry: A practical method for analysis. *Applied Ergonomics*, 8, 199-201.
- [15] Kant, I., Notermans, J.H.V., & Borm, P.J.A. (1990). Observations of working postures in garages using the Ovako working posture analysing system (OWAS) and consequent workload reduction recommendations, *Ergonomics*, 33(2), 209-220.
- [16] Kivi, P. & Mattila, M. (1991). Analysis and improvement of work postures in the building industry: Application of the computerised OWAS method. *Applied Ergonomics*, 22, 43-48.
- [17] Pinzke, S. & Kopp, L. (2001). Marker-less systems for tracking working postures—results from two experiments. *Applied Ergonomics*, 32(5), 461-471.
- [18] Fıđlalı, N., Cihan, A., Esen, H., Fıđlalı, A., Çeşmeci, Güllü, M.K., & Yılmaz, M.K. (2015). Image processing-aided working posture analysis: I-OWAS. *Computers & Industrial Engineering*, 85, 384-394.
- [19] Hignett, S. & McAtamney, L. (2000). Rapid Entire Body Assessment (REBA). *Applied Ergonomics*, 31, 201-205.
- [20] Enez, K. & Nalbantođlu, S.S. (2019). Comparison of ergonomic risk assessment outputs from OWAS and REBA in forestry timber harvesting. *International Journal of Industrial Ergonomics*, 70, 51-57.
- [21] McAtamny, L. & Corlett, E.N. (1993). RULA: a survey method for the investigation of work-related upper limb disorders. *Applied Ergonomics*, 24(2), 91-99.
- [22] Manghisi, V.M., Uva, A.E., Fiorentino, M., Bevilacqua, V., Trotta, G.F., & Monno, G. (2017). Real time RULA assessment using Kinect v2 sensor. *Applied Ergonomics*, 65, 481-491.
- [23] Li, L., Martin, T., & Xu, X. (2020). A novel vision-based real-time method for evaluating postural risk factors associated with musculoskeletal disorders. *Applied Ergonomics*, 87, 103138.
- [24] NIOSH (1981). Work Practices Guide for Manual Lifting, DHHS (NIOSH) Publication, No. 81-122, National Institute for Occupational Safety and Health, Cincinnati, OH
- [25] Waters, T.R., Putz-Anderson, Garg, A., & Fine, L.J. (1993). Revised NIOSH equation for the design and evaluation of manual lifting tasks. *Ergonomics*, 36(7), 749-776.
- [26] Waters, T.R., Lu, M.-L., & Occhipinti, E. (2007). New procedure for assessing sequential manual lifting jobs using the revised NIOSH lifting equation. *Ergonomics*, 50(11), 1761-1770.
- [27] Waters, T., Occhipinti, E., Colombini, D., Alvarez-Casado, E., & Fox, R. (2016). Variable lifting index (VLI). *Human Factors*, 58(5), 695-711.
- [28] Garg, A., & Kapellusch, J. M. (2016). The cumulative lifting index (CULI) for the revised NIOSH lifting equation. *Human Factors*, 58(5), 683-694.
- [29] Occhipinti, E. (1998). OCRA: a concise index for the assessment of exposure to repetitive movements of the upper limbs. *Ergonomics*, 41(9), 1290-1311.
- [30] Schaub, K., Caragnano, G., Britzke, B., & Bruder, R. (2013). The European assembly worksheet. *Theoretical Issues in Ergonomics Science*, 14(6), 616-639.

- [31] Occhipinti, E., & Ghibaudo, L. (2019). Development of a risk assessment procedure for upper limbs based on combined use of EAWS 4th section and OCRA high precision checklist. *20th Congress of the International Ergonomics Association, IEA 2018*. Advances in Intelligent Systems and Computing, 820, 793-799.
- [32] Chander, D.S. & Cavatorta, M.P. (2017). An Observational method for Postural Ergonomic Risk Assessment (PERA). *International Journal of Industrial Ergonomics*, 57, 32-41.
- [33] Winter, D. A. (2011). バイオメカニクス 人体運動の力学と制御, 原著第4編, 長野明紀・吉岡伸輔 訳, ラウンドフラット.
- [34] Neumann, D. A. (2012). 筋骨格系のキネシオロジー 原著第2版, 嶋田智明・有馬慶美 訳, 医歯薬出版.
- [35] Chaffin, D.B., Andersson, G.B.J., & Martin, B.J. (2006). *Occupational Biomechanics 4th ed.* Wiley-Interscience.
- [36] Zhang, L. & Brunnett, G. (2014). Combining inverse blending and Jacobian-based inverse kinematics to improve accuracy in human generation. *Computer Animation and Virtual Worlds*, 27, 3-13.
- [37] 佐藤貴子, 永野志保, 富井尚志, 有澤博, 酒井直隆 (2001). 骨格モデルを用いた人体動作データベースの構築. *情報処理学会論文誌: データベース*, 42, 92-102.
- [38] Guerra-Filho, G. & Biswas, A. (2012). The human motion database: A cognitive and parametric sampling of human motion. *Image and Vision Computing*, 30, 251-261.
- [39] Chaffin, D.B. (2008). Digital human modeling for workspace design. *Reviews of Human Factors and Ergonomics*, 4(1), 41-74.
- [40] Zhang, X. & Chaffin, D.B. (2006). Digital human modeling for computer-aided ergonomics. *Interventions, Controls, and Applications in Occupational Ergonomics*, p. Chapter 10.
- [41] Chaffin, D.B. & Erig, M. (1991). Three-dimensional biomechanics static strength prediction model sensitivity to postural and anthropometric inaccuracies. *IIE Transactions*, 23, 215-227.
- [42] Chaffin, D.B., Faraway, J.J., Zhang, X., & Woolley, C.B. (2000). Stature, age, and gender effects on reach motion postures. *Human Factors*, 42, 408-420.
- [43] Bernstein, N. (1967). *The Coordination and Regulation of Movements*, Pergamon Press: Oxford.
- [44] Plantard, P., Muller, A., Pontonnier, C., Dumont, G., Shum, H.P.H., & Multon, F. (2017). Inverse dynamics based on occlusion-resistant Kinect data: Is it usable for ergonomics? *International Journal of Industrial Ergonomics*, 61, 71-80.
- [45] Steinebach, T., Grosse, E.H., Glock, C.H., Wakula, J., & Lunin, A. (2020). Accuracy evaluation of two markerless motion capture systems for measurement of upper extremities: Kinect V2 and Captiv. *Human Factors and Ergonomics in Manufacturing & Service Industries*, 30, 291-302.
- [46] Cao, Z., Simon, T., Wei, S.E., & Sheikh, Y. (2017). Realtime multi-person 2D pose estimation using part affinity fields. *Computer Vision and Pattern Recognition*. <https://arxiv.org/abs/1611.08050>.
- [47] Cao, Z., Simon, T., Wei, S.E., & Sheikh, Y. (2019). OpenPose: Realtime Multi-person 2D Pose

- Estimation Using Part Affinity Fields. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. <https://arxiv.org/abs/1812.08008>.
- [48] Nakano, N., Sakura, T., Ueda, K., Omura, L., Kimura, A., Iino, Y., Fukushima, S., & Yoshioka, S. (2019). Evaluation of 3D markerless motion capture accuracy using OpenPose with multiple video cameras. *Frontiers in Sports and Active Living*, 2, 50.
- [49] Fernández, M.M., Fernández, J.Á., Bajo, J.M., & Delrieux, C.A. (2020). Ergonomic risk assessment based on computer vision and machine learning. *Computers & Industrial Engineering*, 149, 106816.
- [50] Ota, M., Tateuchi, H., Hashiguchi, T., Kato, T., Ogino, Y., Yamagata, M., & Ichihashi, N. (2020). Verification of reliability and validity of motion analysis systems during bilateral squat using human pose tracking algorithm. *Gait & Posture*, 80, 62-67.
- [51] Chen, C., Wang, T., Li, D., & Hong, J. (2020). Repetitive assembly action recognition based on object detection and pose estimation. *Journal of Manufacturing Systems*, 55, 325-333.
- [52] McCulloch, W.S. & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5, 115-133.
- [53] McCulloch, W.S. & Pitts, W. (1990). A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biology*, 52, 99-115.
- [54] Ciresan, D.C., Meier, J., & Schmidhuber, J. (2012). Multi-column deep neural networks for image classification. In: *2012 IEEE Conference on Computer Vision and Pattern Recognition*, IEEE.
- [55] Lawrence, S., Giles, L., Tsoi, A.C., & Back, A.D. (1997). Face recognition: a convolutional neural-network approach. *IEEE Transactions on neural networks*, 8, 98-113.
- [56] Kong, W., Dong, Z.Y., Jia, Y., Hill, D.J., Xu, Y., & Zhang, Y. (2017). Short-Term Residential Load Forecasting Based on LSTM Recurrent Neural Network. *IEEE Transactions on Smart Grid*, 10, 841-851.
- [57] 酒見悠介, 森野佳生 (2019). スパイクニューラルネットワークにおける深層学習. 生産研究, 71(2), 159-167.
- [58] Yang, Z., Chen, Y., Wang, J., & Gong, H. (2017). Recognizing the breathing resistances of wearing respirators from respiratory and sEMG signals with artificial neural networks. *International Journal of Industrial Ergonomics*, 58, 47-54.
- [59] Kim, Y., Choi, E.S., Seo, J., Choi, W., Lee, J., & Lee, K. (2019). A novel approach to predicting human ingress motion using an artificial neural network. *Journal of Biomechanics*, 84, 27-35.
- [60] Vapnik, V. (1995). *The nature of statistical learning theory*. New York: Springer-Verlag.
- [61] Masoud, H.I., Reed, M.P., Paynabar, K., Wang, N., Jin, J.(J.), Wan, J., Kozak, K.K., & Gomez-Levi, G. (2016). Predicting subjective response from human motion: application to vehicle ingress assessment. *Journal of Manufacturing Science and Engineering*, 138(6), 061001.
- [62] Mangeli, M., Shahraki, A. & Saljooghi, F.H. (2019). Improvement of risk assessment in the FMEA using nonlinear model, revised fuzzy TOPSIS, and support vector machine. *International Journal of*

Industrial Ergonomics, 69, 209-216.

- [63] Karthick, P.A., Ghosh, D.M., & Ramakrishnan, S. (2018). Surface electromyography based muscle fatigue detection using high-resolution time-frequency methods and machine learning algorithms. *Computer Methods and Programs in Biomedicine*, 154, 45-56.
- [64] Wang, L., Hu., W., & Tan., T. (2003). Recent developments in human motion analysis. *Pattern Recognition*, 36, 585-601.
- [65] Lim, C.H., Vats, E., & Chan, C.S. (2015). Fuzzy human motion analysis: A review. *Pattern Recognition*, 48, 1773-1796.
- [66] Aggarwal, J.K. & Cai, Q., (1999). Human motion analysis: A review. *Pattern and Image Understanding*, 73(3), 428-440.
- [67] Yang, Y.H. & Levine, M.D. (1992). The background primal sketch: An approach for tracking moving objects. *Machine Vision and Applications*, 5, 17-34.
- [68] Stauffer, C. & Grimson, M. (1999). Adaptive background mixture models for real-time tracking. *Proceedings of the IEEE CS Conference on Computer Vision and Pattern Recognition*, 2, 246-252.
- [69] Lipton, A.J., Fujiyoshi, H., & Patil, R.S. (1998). Moving target classification and tracking from real-time video. *Proceedings of the IEEE Workshop on Applications of Computer Vision*, 8-14.
- [70] Nayak, N.M., Zhu, Y., & Roy-Chowdhury, A.K. (2013). Vector field analysis for multi-object behavior modeling. *Image and Vision Computing*, 31, 460-472.
- [71] Shen, W., Jiang, Y., Gao, W., Zeng, D., & Wang, X. (2016). Shape recognition by bag of skeleton-associated contour parts. *Pattern Recognition Letters*, 83, 321-329.
- [72] Najva, N. & Edet Bijoy, K. (2016). SIFT and tensor based object detection and classification in videos using deep neural networks. *Procedia Computer Science*, 93, 351-358.
- [73] Chan, C.K., Loh, W.P., & Abd Rahim, I. (2016). Human motion classification using 2D stick-model matching regression coefficients. *Pattern Recognition Letters*, 283, 70-89.
- [74] Ma, M., Marturi, N., Li, Y., Stolkin, R., & Leonardis, A. (2016). A local-global coupled-layer puppet model for robust online human pose tracking. *Computer Vision and Image Understanding*, 153, 163-178.
- [75] Moutzouris, A., Martinez-del-Rincon, J., Nebel, J.C., & Makrisa, D. (2015). Efficient tracking of human poses using a manifold hierarchy. *Computer Vision and Image Understanding*, 132, 75-86.
- [76] Wren, C.R., Clarkson, B.P., & Pentland, A. (2000). Understanding purposeful human motion. *Proceedings of the International Conference on Automatic Face and Gesture Recognition*, France.
- [77] Isard, M. & Blake, A. (1996). Contour tracking by stochastic propagation of conditional density. *Proceedings of the European Conference on Computer Vision*, 343-356.
- [78] Vaughan, N. & Gabrys, B. (2016). Comparing and combining time series trajectories using dynamic time warping. *Procedia Computer Science*, 96, 465-474.
- [79] 松尾直志, 白井良明, 島田伸敬 (2001). 手話単語認識のための動作の多様性に応じた HMM

- 生成. 電子情報通信学会技術研究報告, WIT, 福祉情報工学 101 (264), 37-42.
- [80] Eimezain, M., Al-Hamadi, A., Appenrodt, J., & Michaelis, B. (2008). A Hidden Markov Model-based continuous gesture recognition system for hand motion trajectory. *Pattern Recognition 19th International Conference on Pattern Recognition*.
- [81] Polana, R. & Nelson, R. (1994). Low level recognition of human motion. *Proceedings of the IEEE CS Workshop on Motion of Non-Rigid and Articulated Objects*, Austin, TX, 77-82.
- [82] Liu, M., Liu, H., Sun, Q., Zhang, T., & Ding, R. (2016). Salient pairwise spatio-temporal interest points for real-time activity recognition. *CAAI Transactions on Intelligence Technology*, 1, 14-29.
- [83] Chomat, O. & Crowley, J.L. (1998). Recognizing motion using local appearance. *International Symposium on Intelligent Robotic Systems*, University of Edinburgh.
- [84] San-Segundo, R., Montero, J.M., Barra-Chicote, R., Fernández, F., & Pardo, J.M. (2016). Feature extraction from smartphone inertial signals for human activity segmentation. *Signal Processing*, 120, 359-372.
- [85] Kadrolkar, A. & Sup IV, F.C. (2017). Intent recognition of torso motion using wavelet transform feature extraction and linear discriminant analysis ensemble classification. *Biomedical Signal Processing and Control*, 38, 250-264.
- [86] Masoud, H.I., Zerehsaz, Y., & Jin, J.(J.) (2017). Analysis of human motion variation patterns using UMPCA. *Applied Ergonomics*, 59, 401-409.
- [87] Li, B., Meng, Q., & Holstein, H. (2008). Articulated motion reconstruction from feature points. *Pattern Recognition*, 41, 418-431.
- [88] Troje, N.F. (2002). Decomposing biological motion: a framework for analysis and synthesis of human gait patterns. *Journal of Vision*, 2, 371-387.
- [89] Takano, W. & Nakamura, Y. (2016). Real-time Unsupervised Segmentation of human whole-body motion and its application to humanoid robot acquisition of motion symbols. *Robotics and Autonomous Systems*, 75, 260-272.
- [90] Babič, J., Safonova, A., Pan, J., Faloutsos, C., Hodgins, J., & Pollard, N. (2004). Segmenting motion capture data into distinct behaviors. *Proceedings of Graphics Interface 2004*, Canadian Human-Computer Communications Society, 185-194.
- [91] Chandola, V., Banerjee, A., & Kumar, V. (2009). Anomaly detection: a survey. *ACM Computing Surveys (CSUR)*.
- [92] Grubbs, F.E. (1969). Procedures for detecting outlying observations in samples. *Technometrics*, 11, 1-21.
- [93] Barnett, V. & Lewis, T. (1994). *Outliers in Statistical Data*, 3rd ed. John Wiley & Sons.
- [94] Hodge, V.J. & Austin, J. (2004). A survey of outlier detection methodologies. *Artificial Intelligence Review*, 22, 85-126.
- [95] Schölkopf, B., Platt, J.C., Shawe-Taylor, J., Smola, A.J., & Williamson, R.C. (2001). Estimating the

- support of a high-dimensional distribution. *Neural Computation*, 13, 1443-1471.
- [96] Xiao, Y., Wang, H., Zhang, L., & Xu, W. (2014). Two methods of selecting Gaussian kernel parameters for one-class SVM and their application to fault detection. *Knowledge-Based Systems*, 59, 75-84.
- [97] Xu, D., Ricci, E., Yan, Y., Song, J., & Sebe, N. (2015). Learning deep representations of appearance and motion for anomalous event detection. *British Machine Vision Conference*.
- [98] Mygdalis, V., Iosifidis, A., Pitas, T.I. (2016). Graph embedded one-class classifiers for media data classification. *Pattern Recognition*, 60, 585-595.
- [99] Perdisci, R., Gu, C., & Lee, W. (2006). Using an ensemble of one-class SVM classifiers to harden payload-based anomaly detection systems. *IEEE International Conference on Data Mining*, 488-498.
- [100] Chihara, T., Kobayashi, F., & Sakamoto, J. (2020). Evaluation of mental workload during automobile driving using one-class support vector machine with eye movement data. *Applied Ergonomics*, 89, 103201.
- [101] Knorr, E.M. & Ng, R.T. (1998). Algorithms for mining distance-based outliers in large datasets. *VLDB '98: Proceedings of the 24rd International Conference on Very Large Data Bases*, 392-403.
- [102] Breuning, M.M., Kriegel, H.P., & Ng, R.T. (2000). LOF: identifying density-based local outliers. *SIGMOD '00: Proceedings of the 2000 ACM SIGMOD international conference on Management*, 93-104.
- [103] 井出剛, 杉山将 (2015). 異常検知と変化検知. 東京: 講談社.
- [104] 山西健司 (2015). 異常検知: 外れ値検知と変化検知 (異常検知と変化点検出). 日本信頼性学会誌 信頼性, 37(5), 134-143.
- [105] Kawahara, Y. & Sugiyama, M. (2009). Sequential change-point detection based on direct density-ratio estimation. *SIAM International Conference on Data Mining*, 389-400.
- [106] Aminikhanghahi, S. & Cook, D.J. (2017). A survey of methods for time series change point detection. *Knowledge and Information Systems*, 51, 339-367.
- [107] Ide, T., & Inoue, K. (2004). Knowledge discovery from heterogeneous dynamic systems using change-point correlations. In H. Kargupta, J. Srivastava, C. Kamath & A. Goodman (Eds.), *Proceedings of the 2005 SIAM International Conference on Data Mining* (pp. 571-576). Philadelphia, PA: Society of Industrial and Applied Mathematics.
- [108] Moskvina, V. & Zhigljavsky, A. (2003). An algorithm based on singular spectrum analysis for change-point detection, *Communications in Statistics—Simulation and Computation*, 32(2), 319-352.
- [109] 高橋弘毅, 神尾郁好, 秋月拓磨, 章忠 (2019). 特異値分解による個人特徴抽出とその物理的意味検討のためのセンサ寄与の把握. 知能と情報 (日本知能情報ファジィ学会誌), 31, 603-607.
- [110] 三嶋賢一, 金田さやか, 中西弘明, 榎木哲夫, 堀口由貴男 (2011). 特異値分解を用いた動作における個人間の類似と差異の抽出. 電気情報通信学会論文誌 A, J94-A(4), 293-302.

- [111] 林祐一郎, 辻内伸好, 中村匠汰, 牧野裕太, 浅野真由, 松田靖史, 土屋陽太郎 (2016). 関節モーメント・角度を含めた下肢関節回転運動の定量的な解析手法の提案. *日本機械学会論文集*, 82(834), 15-00344.
- [112] Alonso, F.J. & Salgado, D.R. (2005). Application of singular spectrum analysis to tool wear detection using sound signals. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, 219(9), 703-710.
- [113] Salgado, D.R. & Alonso, F.J. (2006). Tool wear detection in turning operations using singular spectrum analysis. *Journal of Materials Processing Technology*, 171(3), 451-458.
- [114] Kilundu, B., Dehombreux, P., & Chimentin, X. (2011). Tool wear monitoring by machine learning techniques and singular spectrum analysis. *Mechanical Systems and Signal Processing*, 25(1), 400-415.
- [115] Alonso, F.J., Del Castillo, J.M., & Pintado, P. (2005). Application of singular spectrum analysis to the smoothing of raw kinematic signals. *Journal of Biomechanics*, 38, 1085-1092.
- [116] Maddirala, A.K. & Shaik, R.A. (2016). Motion artifact removal from single channel electroencephalogram signals using singular spectrum analysis, *Biomedical Signal Processing and Control*, 30, 79-85.
- [117] Mourad, N. (2019). ECG denoising algorithm based on group sparsity and singular spectrum analysis. *Biomedical Signal Processing and Control*, 50, 62-71.
- [118] Jarchi, D., Wong, C., Kwasnicki, R.M., Heller, B., Tew, G.A., & Yang, G.Z. (2014). Gait parameter estimation from miniaturized ear-worn sensor using singular spectrum analysis and longest common subsequence, *IEEE Transactions on Biomedical Engineering*, 61(4), 1261-1273.
- [119] Vaisman, L., Zariffa, J., & Popovic, M.R. (2010). Application of singular spectrum-based change-point analysis to EMG-onset detection. *Journal of Electromyography and Kinesiology*, 20(4), 750-760.
- [120] 徳永寿慧, 金田さやか, 中西弘明, 榎木哲夫 (2012). 特異スペクトル変換による動作変化点列を用いた動作解析法. *知能と情報 (日本知能情報フレンジイ学会誌)*, 24, 526-535.
- [121] Tamura, Y., Umetani, T., & Nakamura, H. (2015). Detection of finger gesture using singular spectrum transformation. *Journal of Physics: Conference Series*, 574, 012109.
- [122] Ide, T., Lozano, A.C., Abe, N., & Liu, Y. (2009). Proximity-based anomaly detection using sparse structure learning. *Society for Industrial and Applied Mathematics - 9th SIAM International Conference on Data Mining 2009, Proceedings in Applied Mathematics*, 96-107.
- [123] Dempster, A.P. (1972). Covariance selection. *Biometrics*, 28(1), 157-175.
- [124] Meinshausen, N. & Bühlmann, P. (2006). High-dimensional graphs and variable selection with the lasso. *Annals of Statistics*, 34(3), 1436-1462.
- [125] Firedman, J., Hastie, T., & Tibshirani, R. (2008). Sparse inverse covariance estimation with the graphical lasso. *Biostatistics*, 9(3), 432-441.

- [126] Sun, S., Huang, R., & Gao, Y. (2012). Network-Scale Traffic Modeling and Forecasting with Graphical Lasso and Neural Networks. *Journal of Transportation Engineering*, 138(11).
- [127] Li, Q., Qiao, M., Bian, W., & Tao, D. (2016). Conditional graphical lasso for multi-label image classification. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2977-2986.
- [128] Yan, C.G., Craddock, R.C., He, Y., & Milham, M.P. (2013). Addressing head motion dependencies for small-world topologies in functional connectomics. *Frontiers in Human Neuroscience*, 7, 00910.
- [129] Srinivasan, D. & Mathiassen, S.E. (2012). Motor variability in occupational health and performance. *Clinical Biomechanics*, 27, 979-993.
- [130] Cirstea, M.C., Mitnitski, A.B., Feldman, A.G., & Levin, M.F. (2003). Interjoint coordination dynamics during reaching in stroke. *Experimental Brain Research*, 151, 289-300.
- [131] Sun, Q., Liu, H., & Harada, T. (2017). Online growing neural gas for anomaly detection in changing surveillance scenes. *Pattern Recognition*, 64, 187-201.
- [132] Saari, J. Strömbergsson, D., Lundberg, J., & Thomson, A. (2019). Detection and identification of windmill bearing faults using a one-class support vector machine (SVM). *Measurement*, 137, 287-301.
- [133] Mourão-Miranda, J., Hardoon, D.R., Hahn, T., Marquand, A.F., Williams, S.C.R., Shawe-Taylor, J., & Brammer, M. (2011). Patient classification as an outlier detection problem: An application of the One-Class Support Vector Machine. *NeuroImage*, 58(3), 793-804.
- [134] Cao, D., Masoud, O.T., Boley, D., & Papanikolopoulos, N. (2009). Human motion recognition using support vector machines. *Computer Vision and Image Understanding*, 113(10), 1064-1075.
- [135] Khemchandani, R. & Sharma, S. (2016). Robust least squares twin support vector machine for human activity recognition. *Applied Soft Computing*, 47, 33-46.
- [136] Wang, S., Liu, Q., Porikli, F., & Yin, J. (2018). Hyperparameter selection of one-class support vector machine by self-adaptive data shifting. *Pattern Recognition*, 74, 198-211.
- [137] 阿江通良, 湯海鵬, 横井孝志 (1992). 日本人アスリーの身体部分慣性特性の推定. *バイオメカニズム*, 11, 23-33.
- [138] Amundsen, L.R. (1990). *Muscle Strength Testing: Instrumented and Non-Instrumented Systems*. New York: Churchill Livingstone.
- [139] Borg, G. (1998). *Borg's perceived exertion and pain scales*. Stockholm: Human Kinetics.
- [140] Kee, D. & Karwowski, W. (2001). LUBA: an assessment technique for postural loading on the upper body based on joint motion discomfort and maximum holding time, *Applied Ergonomics*, 32, 357-366.
- [141] Mahadevan, S. & Shah, S.L. (2009). Fault detection and diagnosis in process data using one-class support vector machines. *Journal of Process Control*, 19(10), 1627-1639.

- [142] Li, Y. (2011). Selecting training points for one-class support vector machines. *Pattern Recognition Letters*, 32(11), 1517-1522.
- [143] Asadi, H., Yu, D., & Mott, J.H. (2019). Risk factor for musculoskeletal injuries in airline maintenance, repair & overhaul. *International Journal of Industrial Ergonomics*, 70, 107-115.
- [144] Vaughan, J., Rosenbaum, D.A., & Meulenbroek, R.G. (2001). Planning reaching and grasping movements: The problem of obstacle avoidance. *Motor Control*, 5(2), 116-135.
- [145] Zhu, F., Yang, J., Gao, C., Xu, S., Ye, N., & Yin, T. (2016). A weighted one-class support vector machine. *Neurocomputing*, 189, 1-10.
- [146] Krawczyk, B. & Woźniak, M. (2015). Wagging for Combining Weighted One-class Support Vector Machines. *Procedia Computer Science*, 51, 1565-1573.
- [147] Kugiumtzis, D. (1996). State space reconstruction parameters in the analysis of chaotic time series – the role of the time window length. *Physica D: Nonlinear Phenomena*, 95(1), 13-28.
- [148] Kim, H.S., Eykholt, R., & Salas, J.D. (1999). Nonlinear dynamics, delay times, and embedding windows. *Physica D: Nonlinear Phenomena*, 127(1), 48-60.
- [149] Hassani, H., Heravic, S., & Zhigljavsky, A. (2009). Forecasting European industrial production with singular spectrum analysis. *International Journal of Forecasting*, 25(1), 103-118.
- [150] Bouvier, B., Duprey, S., & Dumas, R. (2015). Upper limb kinematics using inertial and magnetic sensors: Comparison of sensor-to-segment calibrations. *Sensors*, 115(8), 18813-18833.
- [151] Taylor, S.A.F., Kedgley, A.E., Humphries, A., & Shaheen, A.F. (2018). Simulated activities of daily living do not replicate functional upper limb movement or reduce movement variability. *Journal of Biomechanics*, 76, 119-128.
- [152] 中村隆一, 斎藤 宏, 長崎 浩 (2003). 基礎運動学第6版. 東京: 医歯薬出版株式会社.
- [153] Allen, T.T. (2010). *Introduction to Engineering Statistics and Lean Sigma 2nd ed.* London: Springer.
- [154] Zandin, K.B. (2003). *MOST Work Measurement Systems 3rd ed.* New York: CRC Press.
- [155] Hansson, G.Å., Balogh, I., Ohlsson, K., Pålsson, B., Rylander, L., & Skerfving, S. (2000). Impact of physical exposure on neck and upper limb disorders in female workers. *Applied Ergonomics*, 31, 301-310.
- [156] International Organization for Standardization. (2014). ISO/TR12295 Ergonomics—Application document for International Standards on manual handling (ISO11228 - 1, ISO11228 - 2, and ISO11228 - 3) and evaluation of static working postures (ISO11226). Retrieved from <https://www.iso.org/obp/ui/#iso:std:iso:tr:12295:ed-1:v1:en>
- [157] Kinali, G., Kara, S., & Yildirim, M.S. (2016). Electromyographic analysis of an ergonomic risk factor: Overhead work. *Journal of Physical Therapy Science*, 28, 1924-1927.
- [158] Cortes, N., Onate, J., & Morrisson, S. (2014). Differential effects of fatigue on movement

- variability. *Gait & Posture*, 39, 888-893.
- [159] Yang, C., Bouffard, J., Srinivassan, D., Ghayourmanesh, S., Begon, M., & Côté, J.N. (2018). Changes in movement variability and task performance during fatiguing repetitive pointing task. *Journal of Biomechanics*, 76, 212-219.
- [160] Falla, D. & Farina, D. (2007). Periodic increases in force during sustained contraction reduce fatigue and facilitate spatial redistribution of trapezius muscle activity. *Experimental Brain Research*, 182, 99-107.
- [161] Madeleine, P. & Madsen, T.M.T. (2009). Changes in the amount and structure of motor variability during a deboning process are associated with work experience and neck-shoulder discomfort. *Applied Ergonomics*, 40, 887-894.
- [162] Moseley, G.L. & Hodges, P.W. (2006). Reduced variability of postural strategy prevents normalization of motor changes induced by back pain: A risk factor for chronic trouble? *Behavioral Neuroscience*, 120, 474-476.
- [163] Madeleine, P. (2010). On functional motor adaptation: From the quantification of motor strategies to the prevention of musculoskeletal disorders in the neck-shoulder region. *Acta Physiologica*, 199, 1-46.
- [164] Stergiou, N., & Decker, L. M. (2011). Human movement variability, nonlinear dynamics, and pathology: Is there a connection? *Human Movement Science*, 30, 869-888.
- [165] Wagner, H., Pfusterschmied, J., Klous, M., von Duvillard, S. P., & Müller, E. (2012). Movement variability and skill level of various throwing techniques. *Human Movement Science*, 31, 78-90.
- [166] Cusumano, J.P. & Dingwell, J.B. (2013). Movement variability near goal equivalent manifolds: Fluctuations, control, and model-based analysis. *Human Movement Science*, 32, 899-923.
- [167] Sedighi, A. & Nussbaum, M.A. (2017). Temporal changes in motor variability during prolonged lifting/lowering and the influence of work experience. *Journal of Electromyography and Kinesiology*, 37, 61-67.
- [168] Longo, A., Meulenbroek, R., Haid, T., & Federolf, P. (2018). Postural reconfiguration and cycle-to-cycle variability in patients with work-related musculoskeletal disorders compared to healthy controls and in relation to pain emerging during a repetitive movement task. *Clinical Biomechanics*, 51, 103-110.
- [169] Hassani, H. (2007). Singular spectrum analysis: Methodology and comparison. *Journal of Data Science*, 5, 239-257.
- [170] Fuller, J.R., Lomond, K.V., Fung, J., & Côté, J.N. (2009). Posture-movement changes following repetitive motion-induced shoulder muscle fatigue. *Journal of Electromyography and Kinesiology*, 19, 1043-1052.
- [171] Adler, P.S. & Clark, K.B. (1991). Behind the learning curve: A sketch of the learning process. *Management Science*, 37, 267-281.

- [172] Srinivasan, D., Samani, A., Mathiassen, S.E., & Madeleine, P. (2015). The size of structure of arm movement variability decreased with work pace in a standardised repetitive precision task. *Ergonomics*, 58, 128-139.
- [173] El Ahrache, K., Imbeau, D., & Farbos, B. (2006). Percentile values for determining endurance times for static muscular work. *International Journal of Industrial Ergonomics*, 36, 99-108.
- [174] Liu, J.Z., Brown, R.W., & Yue, G.H. (2002). A dynamical model of muscle activation, fatigue, and recovery. *Biophysical Journal*, 82, 2344-2359.
- [175] Xia, T., & Frey-Law, L. A. (2008). A theoretical approach for modeling peripheral muscle fatigue and recovery. *Journal of Biomechanics*, 41, 3046-3052.
- [176] Rashedi, E. & Nussbaum, M.A. (2015). Mathematical models of localized muscle fatigue: Sensitivity analysis and assessment of two occupationally-relevant models. *PLoS One*, 10, e0143872.
- [177] Cowley, J.C. & Gates, D.H. (2017). Inter-joint coordination changes during and after muscle fatigue. *Human Movement Science*, 56, 109-118.
- [178] Farina, D., Leclerc, F., Arendt-Nielsen, L., Buttelli, O. & Madeleine, P. (2008). The change in spatial distribution of upper trapezius muscle activity is correlated to contraction duration. *Journal of Electromyography and Kinesiology*, 18, 16-25.
- [179] Côté, J.N., Feldman A.G., Mathieu, P.A., & Mindy, F.L. (2008). Effects of fatigue on intermuscular coordination during repetitive hammering. *Motor Control*, 12, 79-92.
- [180] Gates, D.H. & Dingwell, J.B. (2011). The effects of muscle fatigue and movement height on movement stability and variability. *Experimental Brain Research*, 209, 525-536.
- [181] Huffenus, A.F., Amarantini, D., & Forestier, N. (2006). Effects of distal and proximal arm muscles fatigue on multi-joint movement organization. *Experimental Brain Research*, 170, 438-447.
- [182] McDonald, A.C., Tse, C.T.F., & Keir, P.J. (2016). Adaptations to isolated shoulder fatigue during simulated repetitive work. Part II: Recovery. *Journal of Electromyography and Kinesiology*, 29, 42-49.
- [183] Côté, J.N., Mathieu, P.A., Levin, M.F., & Feldman, A.G. (2002). Movement reorganization to compensate for fatigue during sawing. *Experimental Brain Research*, 146, 394-398.
- [184] Wang, X., O'Dwyer, N., Halaki, M., & Smith, R. (2013). Identifying coordinative structure using principal component analysis based on coherence derived from linear systems analysis. *Journal of Motor Behavior*, 45(2), 167-179.
- [185] Varrel, J., Pologe, S., Manselle, W., Lindenberger, U., & Woollacott, M. (2013). Coordination of degrees of freedom and stabilization of task variables in a complex motor skill: Expertise-related differences in cello bowing. *Experimental Brain Research*, 224(3), 323-334.

謝辞

本研究の遂行と学位論文の執筆過程において、多くの方々にご指導を賜りましたことをここに記し、深く感謝を申し上げる次第です。

本学位論文は東京都立大学 瀬尾明彦 教授のご指導の下で、まとめたものです。はじめに著者が、人間工学分野の研究者を目指すにあたり、その道の厳しさ、やりがいなどをご教示賜り、深く感謝いたします。また、著者が至らぬことで多大なご迷惑をかけたにも関わらず、懇切丁寧なご指導、ご鞭撻と適切なご助言をいただいたことに厚く御礼を申し上げます。

東京都立大学 長谷和徳 教授、同大 藤江裕道 教授、同大 梶原康博 教授には、審査の過程で有益なご指導とご助言を賜り、多角的な視点に基づくご指摘をいただきました。深く感謝すると共に御礼を申し上げます。

本研究の遂行にあたりまして実験の補助および被験者を快く引き受けてくれた応用人間工学研究室の皆様および実験に協力していただいた被験者の皆様へ深く感謝いたします。

最後に、本学位論文の完成は家族の理解と協力無くしては成しえないことでした。博士後期課程に進学する機会を与えてくださり、私を支援し続けてくれた家族に深く感謝いたします。

2021年2月5日

平内 和樹