

NAIST-IS-MT1551009

修士論文

ガウス過程を用いた判別的な動作意図予測器と 起立支援ロボットへの応用

石倉 裕貴

2017 年 3 月 13 日

奈良先端科学技術大学院大学
情報科学研究科 情報科学専攻

本論文は奈良先端科学技術大学院大学情報科学研究科に
修士（工学）授与の要件として提出した修士論文である。

石倉 裕貴

審査委員：

杉本 謙二 教授	（主指導教員）
小笠原 司 教授	（副指導教員）
松原 崇充 准教授	（副指導教員）
南 裕樹 客員准教授	（副指導教員）
小林 泰介 助教	（副指導教員）

ガウス過程を用いた判別的な動作意図予測器と 起立支援ロボットへの応用*

石倉 裕貴

内容梗概

近年，動作支援ロボットは高齢者や身障者の動作支援や介護者の作業支援などの用途が想定されることから研究が活発化している．動作意図予測に関する研究において，リハビリのための単一の動作のみを行う状況を想定しているものが多い．しかしながら，日常生活において人間は多様な動作を行っており，対象動作以外の動作も多く存在ため，先行研究を模した手法では誤った支援を行ってしまう危険がある．日常動作を支援するロボットへの応用を考えると，多様な動作の中から対象動作を判別し，同時に動作意図予測を行う予測器が事実上必要である．

そこで本研究では，ガウス過程に基づいた対象動作と非対象動作との判別性を有する確率的な動作意図予測器の設計手法を提案する．具体的には，センサ入力から動作意図予測を行うガウス過程モデルとして考え，対象動作と非対象動作について判別的な潜在特徴空間を中間層に持つ階層ガウス過程モデルを提案する．これにより，非対象動作に対する誤った予測を回避した動作意図予測が期待できる．

本研究では，人の日常生活における基本動作の1つである椅子からの起立動作を対象として，筋電位信号などのセンサデータから，起立動作中の臀部が椅子の座面から離床する瞬間を予測する問題を考える．さらに，提案手法による動作意図推定器を実装した電動座椅子型ロボットにより実機実験を実施した．実験の結果，提案手法の有効性を確認し，起立支援効果があることを示した．

キーワード

意図予測，機械学習，ガウス過程，潜在空間，起立支援ロボット

*奈良先端科学技術大学院大学 情報科学研究科 情報科学専攻 修士論文, NAIST-IS-MT1551009, 2017年3月13日.

Learning Latent Features for Discriminative Intention Prediction using Gaussian Process: Application to Sit-to-Stand Assistance*

Yuki Ishikura

Abstract

Estimation and prediction of user motion intention are crucial for assistive robotics. Many previous studies focus on only one motion as the target motion. However, in practice, the user may perform other motions. If a motion intention predictor constructed only with the data observed from the target motion is applied for other non-target motions without motion discrimination, incorrect intention is predicted, and improper and non-safe assistance might be applied to the user. To overcome this issue, in this study, we propose an approach for discriminative intention prediction. Our method learns latent feature space based on discriminative Gaussian process latent variable models by utilizing data from both target and non-target motions. Then, we construct a hierarchical Gaussian process model as a discriminative motion intention predictor. We applied it for the task of the sit-to-stand timing prediction from surface electromyography signals. The experimental results show that our motion predictor has capabilities of both intention prediction and motion discrimination. Furthermore, we implemented our intention predictor on a sit-to-stand assistance robot and conducted subjective experiments. Experimental results suggest that our approach can reduce the risk of improper and non-safe assistance when the user performs non-target motions.

Keywords:

Intention Prediction, Machine Learning, Gaussian Process, Latent Variable, Sit-to-Stand Assist Robot

*Master's Thesis, Department of Information Science, Graduate School of Information Science, Nara Institute of Science and Technology, NAIST-IS-MT1551009, March 13, 2017.

目次

図目次	v
表目次	vi
第 1 章 序論	1
1.1 はじめに	1
1.2 関連研究	2
1.3 本研究の目的	5
1.4 本論文の構成	5
第 2 章 ガウス過程を用いた判別的な動作意図予測器	6
2.1 準備	6
2.1.1 ガウス過程 (GP : Gaussian Process)	6
2.1.2 ガウス過程回帰 (GPR : Gaussian Process Regression)	6
2.1.3 Gaussian Process Latent Variable Models	7
2.1.4 Discriminative-Gaussian Process Latent Variable Models	8
2.1.5 Toy Problem への適用例	10
2.2 提案手法	11
2.2.1 問題の定式化	11
2.2.2 学習ステップ	13
2.2.3 予測ステップ	14
第 3 章 起立動作意図予測への適用	17
3.1 実験の目的	17
3.2 実験データ	17
3.3 予測器の設定	22
3.4 実験結果	22
3.5 考察	24
第 4 章 電動座椅子型ロボットを用いた起立支援応用	28

4.1	目的	28
4.2	実験システムの構成	28
4.3	応用結果	30
4.4	考察	32
第 5 章	まとめと今後の課題	34
	謝辞	35
	参考文献	36
	付録	40
A	Toy Proplem の擬似入力について	40
B	起立動作	41
C	筋電位信号	42
D	起立支援応用の追加結果	43

図目次

1	提案する動作意図予測器	2
2	潜在特徴量空間	10
3	提案する階層型動作意図予測器	11
4	学習ステップ時のグラフィカルモデル	12
5	予測時のグラフィカルモデル	14
6	センサ情報からの起立時間予測	18
7	実験環境	18
8	椅子からの起立動作	19
9	上半身を前に倒す動作（非対象動作 1）	19
10	足踏みを行う動作（非対象動作 2）	19
11	筋電位の計測部位	20
12	入力信号	21
13	学習の進行結果	23
14	生成された特徴量空間	24
15	各手法による出力結果	26
16	起立時間予測の誤差	27
17	予測誤差比	27
18	起立支援ロボット	28
19	信号の流れ	29
20	出力パターンによる違い	30
21	筋活動量による起立支援効果 1	33
22	筋活動量による起立支援効果 2	33
23	椅子からの起立動作	41
24	筋電位信号	42
25	出力トルクの各パターンにおける筋活動量	43

表目次

1	各動作に対する予測分散	25
2	制御信号の出力結果	31
3	制御信号と起立支援のタイミング	32
4	提案手法による制御信号の出力結果	44
5	比較手法 (NLS) による制御信号の出力結果	44
6	比較手法 (GPLVM) による制御信号の出力結果	44
7	比較手法 (LDA) による制御信号の出力結果	44

第 1 章 序論

1.1 はじめに

ロボット工学の分野において、動作支援ロボット [1] や協調ロボット [2] によってユーザの意図予測は重要であり様々な研究が行われている [3] [4] [5]. また近年、動作支援ロボットは高齢者や身障者の動作支援や介護者の作業支援などの用途が想定され、研究が活発化している [6] [7] [8]. 物理的な接触を介して人の運動を支援する動作支援ロボットにおいて、ユーザの動作意図をセンサから読み取り、的確な力やタイミングによって支援を実行することは重要である. 本研究では、センサデータからそのようなユーザの動作意図を予測する技術について検討する.

ユーザの動作意図を予測する問題において、ユーザの生体信号および行動パターンは不確実性を伴うため、決定論的に扱うのは難しい. さらに、ユーザの意図予測に関する研究では、取り扱いの簡便さからしばしば対象動作のデータのみから意図予測器が設計される. しかしながら、ユーザが対象動作と異なる動作（以下、非対象動作と呼ぶ）を行った場合、対象動作であるかを判別することなく動作意図を予測するため、ユーザの意図に沿わない危険な支援が実行される恐れがある. よって、対象動作と非対象動作との判別性を考慮した意図予測器の設計が実用上重要と考えられる.

そこで本研究では、ガウス過程に基づいて、対象動作と非対象動作との判別性を有する確率的な動作意図予測器の設計手法を提案する. 具体的には、センサ入力から動作意図を出力とするガウス過程モデルとして考え、対象動作と非対象動作について判別的な潜在特徴空間を中間層に持つ階層ガウス過程モデルを提案する. 提案手法では、判別的な潜在変数を導入することにより、潜在特徴空間上において、対象動作と非対象動作の潜在変数が離れるように学習されるため、対象動作に対するセンサデータについては予測分散が小さく、非対象動作に対するセンサデータについては予測分散が大きくなることが考えられる（図 1 参照）. つまり、予測分散の値によって、対象動作と非対象動作とを判別する機能を有する. これにより、非対象動作に対する誤った予測を回避した動作意図予測が行えることが期待できる.

本研究では、人の日常生活における基本動作の 1 つである椅子からの起立動作 [9] を対象として、筋電位信号などのセンサデータから、起立動作中の臀部が椅子の座




図 1: 提案する動作意図予測器

面から離床する瞬間（以下，離座時間と呼ぶ）がいつ発生するのかを予測する問題を考える．ここでは，予測したい意図は離座時間であり，起立動作と非対象動作を含むデータセットを用いて動作意図予測器の構築を行い，有効性の検証実験を実施する．さらに，提案手法による動作意図予測器を実装した電動座椅子型ロボットにより実機実験を実施する．

1.2 関連研究

ロボット工学の分野におけるユーザの動作意図予測は重要であり様々な研究が行われている [10] [11] [12] [13] [14] [15]．例えば Matsubara らは，移動支援車椅子ロボットを用いてユーザの操作ログから目的地の推定を行っている [16]．また Ge らは，人がロボットの手を握り，与える力，位置，速度から人が動かしたい手の動作の推定を行っている [17]．また Yamamoto らは，アシストスーツを用いて，圧力センサから物体を持ち上げる意図を推定している [18]．このように，様々なロボットに対して動作意図の予測が行われている．動作意図予測に関する研究には大きく分けて，1) 単一の動作やタスクに絞り込んだ研究と，2) 複数の動作やタスクについて考えられている研究の 2 種類がある．

1) 単一の動作やタスクに絞り込んだ研究として，Tsukahara らは，対麻痺患者

に対してロボットスーツを用いて動作をサポートする研究を行った。Tsukahara らはロボットスーツの重心位置を考えた二足歩行モデルを提案し、PD 制御を行うことにより起立・着座、起立状態において後退する動作を実現した [19]。また Kato らは、起立動作支援のタイミングについて考え、体幹前傾角と脚の筋電位信号を計測を行い、起立動作における筋肉の活動する順番を示した。さらに、この活動筋の関係に基づいたシーケンス制御により起立動作支援を行った。起立動作支援を行った結果、支援の有無による筋電量を比較し、起立支援ロボットによる支援の有効性を示した [20]。さらに Yu らは、筋骨格モデルを用いて、筋硬直センサから歩行支援を行った。Yu らは筋電位信号と筋硬直センサから動作信号の推定を行っている。また、同様の手法を階段を上る動作にも適用した。さらに、階段を上る動作において、錘を背中に背負い動作を行い支援効果があることを示した [21]。このように、動作支援ロボットにおいても人間の動作意図予測している研究は様々である。

しかしながら、1) 単一の動作やタスクに絞り込んだ研究においては、ユーザが対象となる限定的な単一の動作やタスクのみを行う状況を想定しており、ユーザが異なる動作を行うことについては考えられていない。これは、対象とするユーザがリハビリなど限定的な動作のみを行う状況を想定しているためである。例えば Kato らの研究において、起立動作以外の動作は考慮していないため、着座状態のまま足踏みを行うなどの動作を行った場合には起立支援が行われる可能性があり危険である。この問題を解決するために現在の動作が起立動作であるか否かを判断する手法を新たに導入する必要がある。つまり、1) 単一の動作やタスクに絞り込んだ研究においては、タスクとして考えられている単一の動作以外を行ったときには誤動作が起こることが考えられ、その問題を解決する別の手法を導入する必要がある。その際、導入した新たな手法との関係について新たに議論しなければならない。実際に Kawamoto らは、ロボットスーツ HAL を用いて歩行動作、起立動作、階段を上る動作の 3 種類の動作に対して動作支援を行っており、それぞれの動作についてフェーズを考え、フェーズシーケンス制御により支援を行い、支援の有効性を示している [22]。しかしながら、各動作は別々に行われており、3 種類の動作が混在する状況は考えられていない。したがって、複数の動作が混在する状況を考えてときには、各動作の切り替えをどのように行うのかについて新たに議論しなければならないという問題が挙げられる。よって、単一の動作やタスクを考える研究において

も、対象動作と非対象動作との判別性を考慮することが実用上重要と考えられる。

一方、2) 複数の動作やタスクについて考えられている研究について述べると、Yoshikawa らは、筋電位信号を利用したサポートベクターマシン (SVM : Support Vector Machine) による動作識別法を提案している。筋電義手を制御するために、腕の切断者がイメージしやすい7動作の識別を行っており、健常者の筋電位信号により学習を行い7動作の分類を行えていることを示した [23]。また、Takeda らは、人と協調して行動を行う社交ダンスロボットを用いて、人とロボットが社交ダンスを行う問題について考えた。Takeda らは隠れマルコフモデル (HMM : Hidden Markov Model) に基づく状態遷移モデルを考え、人がロボットに加える力情報から、社交ダンスにおける5種類のステップを予測できることを示した [24]。Bu らは、手の開閉や手首の動きなど6種類の腕の動作を腕の筋電位信号から推定する問題について考えている。6種類の腕の動作の組み合わせによってユーザが行いたいタスクを予測する問題について考え、Bayesian Network を用いて検討した。さらに、ユーザが食事を行う環境を想定し、食事の補助（コップへの給水や食事を口へ運ぶなど）を行うロボットマニピュレータを考え実験を行った。しかしながら、人間の不確実な振る舞いによって、タスクを予測することは難しいという結果が得られたことを報告している [25]。

したがって、2) 複数の動作やタスクについて考えられている研究においては、複数の動作に対して分類を行うことがメインであるため、各行動の多様性を考慮していない。そのため、分類された行動の中においてさらに細やかな動作を行いたい場合には、さらに細かな分類を再度行う必要があると考えられる。また、ロボットへの応用を考えたときに離散化された動作分類における問題点として、各動作において細やかな動作を行えなかったり、入力がない状況に対し初期状態に戻ったりなど、動作や動作間をスムーズに行うことができない問題が挙げられる。実際に Bu らは、考慮していなかった人間の不確実な振る舞いによって予測が難しくなることを示している。よって、行動数や行動の細やかさを考えると分類しなければならない状態数が増えることが考えられ、それに伴った問題（例えば、センサの数や計算コストなど）を解決する手法を新たに議論しなければならない。

1.3 本研究の目的

本研究の目的は，実用的な動作意図予測器の提案である．動作支援ロボットについて考えると，被介助者が支援される動作とは異なる動作を行っているときに，誤って支援が行われてしまうのは安全性の観点から危険である．そのため，対象動作と非対象動作との判別性を考慮した意図予測器の設計が実用上重要と考えられる．

したがって本研究では，対象動作と非対象動作とを判別する機能を有する動作意図予測器の設計手法を提案する．設計手法として，潜在特徴空間を中間層に持つ階層ガウス過程モデルを考え，対象動作に対する動作意図予測の性能を劣化させることなく，動作を判別する機能を有する動作意図予測器を目指す．

1.4 本論文の構成

本論文の構成について述べる．第2章では，本研究において関連するガウス過程に基づく既存手法について述べたあと，提案手法について詳しく説明する．第3章では問題設定として，筋電位信号などのセンサデータから離座時間がいつ発生するのかを予測する問題について考え，提案手法の有効性を確認する．具体的には，椅子からの起立動作を対象動作とし，非対象動作も混在する状況を考えた．計測したセンサデータから動作意図予測器を提案手法によって設計した．設計した動作意図予測器の予測性能を確認するため，他の手法との比較を行い，その結果について説明する．第4章では，応用実験として，実際に電動座椅子型ロボットを用いて起立支援実験を行った．提案手法によって設計した予測器を用いて支援実験を行い，非対象動作に対するロボットの振る舞いについて説明する．また，起立動作に対する支援効果についての説明を行う．

第 2 章 ガウス過程を用いた判別的な動作意図予測器

2.1 準備

本研究では、多次元の生体信号と離座時間との間の非線形性と、人の動作の多様性や生体信号の観測ノイズなどを考慮して、以下のガウス過程に基づく確率的手法を用いる。ここでは、本研究における準備として重要な手法について説明する。

2.1.1 ガウス過程 (GP : Gaussian Process)

ガウス過程とは一般的に関数 $f(\mathbf{x})$ 上の確率分布として定義され、任意の点集合 $x_1, x_2, \dots, x_N$ に対する $f(\mathbf{x})$ の値の同時分布がガウス分布に従うとしたものである。ガウス過程は M 個の変数 $f_1, f_2, \dots, f_M$ の同時分布が、平均と分散共分散の 2 次の統計量によって完全に記述される。

$f(\mathbf{x}, \mathbf{w}) = \mathbf{w}^T \phi(\mathbf{x})$ を考えたとき、 $\mathbf{w}$ はパラメータベクトルであり、 $\phi(\mathbf{x})$ は $\mathbf{x}$ に依存する事前に固定された非線形の基底関数のベクトルを表すとする。 $\mathbf{w}$ の事前分布を決定することで、関数 $f(\mathbf{x}, \mathbf{w})$ に対する事前分布が決まる。また、訓練データ集合が与えられると今度は $\mathbf{w}$ の事後分布が求まる。したがって、 $\mathbf{w}$ の事後分布に対応する回帰関数の事後分布が求まることになり、最終的に新しい入力ベクトル $\mathbf{x}$ に対する予測分布 $p(t|\mathbf{x})$ が導かれる [26][27]。

2.1.2 ガウス過程回帰 (GPR : Gaussian Process Regression)

入力ベクトルを $\mathbf{x} \in \mathbb{R}^d$ 、出力値を z とする。また、観測値は t とし、出力値にノイズが加わったものとする。観測値に加えられるノイズは観測値に対して独立に決定され、ノイズもガウス分布に従う。これを式 (1) に示す。

$$p(t|z) = N(t|z, \beta^{-1}) \quad (1)$$

ここで β はノイズの精度を表す超パラメータである。ノイズは各データ点に対して独立に決まるため、 $\mathbf{z} = [z_1, \dots, z_N]^T$ が与えられた下での観測値 $\mathbf{t} = [t_1, \dots, t_N]^T$

の同時分布は式 (2) に示す等方的なガウス分布に従う.

$$p(\mathbf{t}|\mathbf{z}) = N(\mathbf{t}|\mathbf{z}, \beta^{-1}\mathbf{I}_N) \quad (2)$$

ここで, $\mathbf{I}_N$ は $N \times N$ の単位行列である.

ガウス過程の定義より, 周辺分布 $p(\mathbf{z})$ は, 式 (3) に示される平均が $\mathbf{0}$, 共分散がグラム行列 $\mathbf{K}$ のガウス分布となる.

$$p(\mathbf{z}) = N(\mathbf{z}|\mathbf{0}, \mathbf{K}) \quad (3)$$

ここで, グラム行列 $\mathbf{K}$ の要素 K_{ij} は式 (4) のようなカーネル関数で与えられる.

$$k(\mathbf{x}_n, \mathbf{x}_m) = \theta_1 \exp\left(-\frac{\theta_2}{2} \|\mathbf{x}_n - \mathbf{x}_m\|^2\right) + \theta_3 \mathbf{x}_n^T \mathbf{x}_m \quad (4)$$

入力ベクトル $\mathbf{x}_1, \dots, \mathbf{x}_N$ によって条件付けられたときの周辺分布 $p(\mathbf{t})$ を求めるためには $\mathbf{z}$ について周辺化を行い, 式 (5) のように示される.

$$p(\mathbf{t}) = \int p(\mathbf{t}|\mathbf{z})p(\mathbf{z})d\mathbf{z} = N(\mathbf{t}|\mathbf{0}, \mathbf{K} + \beta^{-1}\mathbf{I}) \quad (5)$$

回帰においては, 訓練データの集合が与えられたときに, 新しい入力に対する観測値を予測することが必要である. 訓練データ集合 $\mathbf{t}_N = [t_1, t_2, \dots, t_N]^T$, $\mathbf{X}_N = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N]^T$ が与えられたとき, 新しい入力ベクトル $\mathbf{x}_{N+1}$ に対する観測値 t_{N+1} の確率分布 $p(t_{N+1}|\mathbf{t}_N)$ を以下に示す.

$$p(t_{N+1}|\mathbf{t}) = \mathcal{N}(t_{N+1}|m(\mathbf{x}_{N+1}), \sigma^2(\mathbf{x}_{N+1})) \quad (6)$$

$$m(\mathbf{x}_{N+1}) = \mathbf{k}_{N+1}^T (\mathbf{K} + \beta^{-1}\mathbf{I})^{-1} \mathbf{t}_N \quad (7)$$

$$\sigma^2(\mathbf{x}_{N+1}) = c - \mathbf{k}_{N+1}^T (\mathbf{K} + \beta^{-1}\mathbf{I})^{-1} \mathbf{k}_{N+1} \quad (8)$$

ここで, $\theta_1, \theta_2, \theta_3$ はハイパーパラメータである. $\mathbf{k}_{N+1}$ は $k(\mathbf{X}_N, \mathbf{x}_{N+1})$ で表される縦ベクトル, $c := k(\mathbf{x}_{N+1}, \mathbf{x}_{N+1}) + \beta^{-1}$ である.

2.1.3 Gaussian Process Latent Variable Models

ガウス過程に基づいた特徴量抽出の手法として Gaussian Process Latent Variable Model (GPLVM) がある [28]. 一般的な特徴抽出法 (あるいは次元圧縮法)

として主成分分析 (PCA : Principal Component Analysis) がある. PCA は訓練データとして与えられたデータセットを用いて固有値分解を行い, 分散の大きいものから順に n 個だけを抽出することによりデータを n 次元に圧縮する手法である. GPLVM は PCA に対して確率的な解法に拡張したものである. また, カーネル関数を用いることにより, PCA の解法内にある共分散行列の計算を陽に計算することなく, 内積計算によって得ることができるため, 高次元データに対応したものである.

ここでは, 入力変数の集合を $\mathbf{Y}_N = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_N]^T$, $\mathbf{y}_i \in \mathbb{R}^D$, それに対する潜在変数の集合を $\mathbf{X}_N = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N]^T$, $\mathbf{x}_i \in \mathbb{R}^d$ とする. それぞれの確率分布の関係式を式 (9) に示す.

$$p(\mathbf{X}, \beta^{-1} | \mathbf{Y}) \propto p(\mathbf{Y} | \mathbf{X}, \beta^{-1}) p(\mathbf{X}) p(\theta) \quad (9)$$

$$p(\mathbf{Y} | \mathbf{X}, \beta^{-1}) = \frac{1}{\sqrt{(2\pi)^{ND} |\mathbf{K}_Y|^D}} \exp \left(-\frac{1}{2} \text{tr}(\mathbf{K}_Y^{-1} \mathbf{Y} \mathbf{Y}^T) \right) \quad (10)$$

ここで, ここで, $\mathbf{K}$ はグラム行列であり, θ はハイパーパラメータ, 式 (10) は潜在変数とハイパーパラメータが与えられたもとにおける入力変数の確率分布である. GPLVM の目的は入力変数の集合を十分に表すことのできるような潜在変数の集合 $\mathbf{X}^*$ とハイパーパラメータ θ^* を求めることである. つまり, 式 (11) に示すような最大化問題となる.

$$\mathbf{X}^*, \theta^* \leftarrow \arg \max_{\mathbf{X}, \theta} \left(\ln \left(\frac{1}{\sqrt{(2\pi)^{ND} |\mathbf{K}_Y|^D}} \exp \left(-\frac{1}{2} \text{tr}(\mathbf{K}_Y^{-1} \mathbf{Y} \mathbf{Y}^T) \right) \right) \right) \quad (11)$$

具体的には, 条件付き確率 $p(\mathbf{Y} | \mathbf{X}, \beta)$ の対数尤度関数を最大化するような潜在変数を求めることに帰着する. 条件付き確率 $p(\mathbf{Y} | \mathbf{X}, \beta)$ の対数尤度関数を以下の式 (12) に示す.

$$\mathcal{L} = -\frac{DN}{2} \ln(2\pi) - \frac{D}{2} \ln |\mathbf{K}| - \frac{1}{2} \text{tr}(\mathbf{K}_Y^{-1} \mathbf{Y} \mathbf{Y}^T) \quad (12)$$

2.1.4 Discriminative-Gaussian Process Latent Variable Models

前節の GPLVM にクラスラベル情報を考慮し, クラス毎に判別的な潜在変数を学習するように拡張されたものが D-GPLVM である [29]. ここでは, 入力変数の

集合を $\mathbf{Y}_N = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_N]^T$, $\mathbf{y}_i \in \mathbb{R}^D$, それに対する潜在変数の集合を $\mathbf{X}_N = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N]^T$, $\mathbf{x}_i \in \mathbb{R}^d$ とする. D-GPLVM は GPLVM に Linear Discriminant Analysis (LDA) の手法を取り入れた手法である. LDA は以下の式 (13) に示すような潜在変数 $\mathbf{X}^*$ を見つける最適化問題である.

$$\mathbf{X}^* \leftarrow \arg \max_{\mathbf{X}} (\text{tr}(\mathbf{S}_b^{-1} \mathbf{S}_w)) \quad (13)$$

$$\mathbf{S}_b = \sum_{l=1}^L \frac{N_l}{N} \left[\frac{1}{N_l} \sum_{k=1}^{N_l} (\mathbf{x}_k^{(l)} - \mathbf{M}_l)(\mathbf{x}_k^{(l)} - \mathbf{M}_l)^T \right] \quad (14)$$

$$\mathbf{S}_w = \sum_{l=1}^L \frac{N_l}{N} (\mathbf{M}_l - \mathbf{M}_0)(\mathbf{M}_l - \mathbf{M}_0)^T \quad (15)$$

ここで, $\mathbf{X}^{(l)} = [\mathbf{x}_1^{(l)}, \dots, \mathbf{x}_{N_l}^{(l)}]^T$ はクラスラベル l を持つ N_l 個の潜在変数, $\mathbf{M}_l$ はクラスラベル l を持つ潜在変数の平均, $\mathbf{M}_0$ は全ての潜在変数の平均である. $\mathbf{S}_b$ は, 潜在空間におけるクラス内分散に関する項である. また, $\mathbf{S}_w$ は, クラス間分散に関する項である. また, 確率分布 $p(\mathbf{X})$ を以下のように定義する (式 (16)).

$$p(\mathbf{X}) = \frac{1}{Z_d} \exp \left(-\frac{1}{\sigma_d^2} \text{tr}(\mathbf{S}_b^{-1} \mathbf{S}_w) \right) \quad (16)$$

ここで, Z_d は正規化係数, σ_d^2 は重みパラメータである. D-GPLVM は, 式 (17) に示すような最大化問題となる.

$$\mathbf{X}^*, \theta^* \leftarrow \arg \max_{\mathbf{X}, \theta} (\ln (p(\mathbf{Y}|\mathbf{X}, \beta^{-1})p(\mathbf{X})p(\theta))) \quad (17)$$

つまり, 以下の式 (18) を最小にするような潜在変数 $\mathbf{X}^*$ を見つけることにより, 特徴量を抽出する手法である.

$$\mathcal{L}_S = \mathcal{L}_r + \sum_i \ln \theta_i + \frac{1}{\sigma_d^2} \text{tr}(\mathbf{S}_b^{-1} \mathbf{S}_w) \quad (18)$$

$$\mathcal{L}_r = \frac{D}{2} \ln |\mathbf{K}_Y| + \frac{1}{2} \text{tr}(\mathbf{K}_Y^{-1} \mathbf{Y} \mathbf{Y}^T) \quad (19)$$

$$K_{Y,ij} = \theta_1 \exp \left(-\frac{\theta_2}{2} \|\mathbf{x}_i - \mathbf{x}_j\|^2 \right) + \theta_3 + \frac{\delta_{\mathbf{x}_i, \mathbf{x}_j}}{\theta_4} \quad (20)$$

$$(21)$$




図 2: 潜在特徴量空間

ここで、 $\delta_{\mathbf{x}_i, \mathbf{x}_j}$ は $i = j$ のとき $\delta_{\mathbf{x}_i, \mathbf{x}_j} = 1$ 、それ以外は $\delta_{\mathbf{x}_i, \mathbf{x}_j} = 0$ となるデルタ関数である。 $\mathcal{L}_S$ について説明する。 まず、式 (18) の第一項である式 (19) は、潜在空間が与えられたときの入力変数に対する確率分布 $p(\mathbf{Y}|\mathbf{X})$ についての対数尤度関数である。 式 (18) の第二項は、過学習を抑える項である。 第三項は、クラスラベルを用いた潜在空間におけるデータ間の距離に関する項である。

2.1.5 Toy Problem への適用例

ここでは、前述した GPLVM と D-GPLVM の潜在変数の学習結果による違いを例題によって示す。 30 次元の擬似入力から 2 次元の潜在変数空間をそれぞれの手法により学習した結果を図 2 に示す。 擬似入力の生成については付録 A に記載する。 擬似入力のクラスは 3 クラスであり、各クラスの潜在変数を赤、青、緑のマーカによって示す。 図中の白黒で示すのは中間層の確率分布の分散である。 白いほど中間層において確率分布の値が大きいことを表している。 結果より、GPLVM は各クラスが混在した潜在特徴空間になっているのに対し、D-GPLVM はクラスごとにまとまった潜在特徴空間を生成していることが分かる。




図 3: 提案する階層型動作意図予測器

2.2 提案手法

2.2.1 問題の定式化

提案手法では、多次元のセンサ情報から動作意図を予測する問題について考える。その際、対象動作に対する動作意図の予測性能と、対象動作と非対象動作との判別性の両立を目指した動作意図予測器を設計する。つまり、対象動作に対する動作意図予測に重要な情報を残しつつ、対象動作と非対象動作とを判別するような機能を有する動作意図予測器を設計することが目的である。具体的には、入力層と出力層との間に潜在特徴空間を持つモデルを考える。D-GPLVM の手法をベースとして、対象動作に対するセンサデータについては予測分散が小さく、非対象動作に対するセンサデータについては予測分散の大きくなるような潜在特徴空間を学習させ、予測分散の値によって対象動作と非対象動作とを判別する機能を有するような動作意図予測器を設計する。また、各層の確率モデルを考えた目的関数によって同時に学習を行うことにより、対象動作に対する動作意図予測の性能低下を防ぐ。これにより、対象動作に対する動作意図予測の性能を維持しつつ、予測分散の値によって対象動作と非対象動作とを判別する動作意図予測器を設計する。

ここでは、入力されるセンサデータを $\mathbf{y} \in \mathbb{R}^D$ 、その入力に対する潜在変数を $\mathbf{x} \in \mathbb{R}^d$ 、出力を z と表記する。また、入力変数の訓練データ集合を $\mathbf{Y} = [\mathbf{y}_1, \dots, \mathbf{y}_N]^T$ 、入力変数に対する潜在変数の集合を $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_N]^T$ と表記する。入力変数の集合には対象動作に対するセンサデータの集合




図 4: 学習ステップ時のグラフィカルモデル

$\mathbf{Y}_p = [\mathbf{y}_{p1}, \dots, \mathbf{y}_{pN_p}]^T$ と、非対象動作に対するセンサデータの集合 $\mathbf{Y}_n = [\mathbf{y}_{n1}, \dots, \mathbf{y}_{nN_n}]^T$ があり $\mathbf{Y} = \{\mathbf{Y}_p, \mathbf{Y}_n\}$ であり、同様にそれぞれの動作に対する潜在変数の集合は $\mathbf{X} = \{\mathbf{X}_p, \mathbf{X}_n\}$ である。また、それぞれにラベル情報 $\mathbf{l}_p = [l_{p1}, \dots, l_{pN_p}]^T, \mathbf{l}_n = [l_{n1}, \dots, l_{nN_n}]^T$ が付加されている。さらに、 $\mathbf{y}_p$ に関してのみ、出力データ z_p があるため、出力データの集合は $\mathbf{z}_p = \mathbf{z} = [z_1, \dots, z_{N_p}]^T$ となる。

予測器の構成には、対象動作に対する予測に重要な情報を持ち、なおかつ動作に対して判別的な潜在空間を生成する学習ステップと、未知入力に対する予測を行う予測ステップの2ステップによって構成される。

2.2.2 学習ステップ

学習ステップにおけるグラフィカルモデルを図 4 に示す．ここでは，対象動作と非対象動作の入力変数のデータ集合 $\{\mathbf{Y}_p, \mathbf{Y}_n\}$ と，それに対するラベル情報の集合 $\{\mathbf{l}_p, \mathbf{l}_n\}$ を全て用いて，判別的な潜在空間 $\mathbf{X}$ ，および $\mathcal{GP}_{x \rightarrow y}$ を学習する．ここで $\mathcal{GP}_{x \rightarrow y}$ とは，潜在変数空間 x から入力空間 y のガウス過程に基づく確率モデルとして表す．また，対象動作に対する潜在変数 $\mathbf{x}_p$ と出力変数 z_p を用いて，ガウス過程予測器 $\mathcal{GP}_{x \rightarrow z}$ を学習する．ここで $\mathcal{GP}_{x \rightarrow z}$ は，潜在変数空間 x から出力空間 z のガウス過程に基づく確率モデルとして表す．さらに，入力変数から潜在空間へのガウス過程予測器 $\mathcal{GP}_{y \rightarrow x}$ を学習する．ここで $\mathcal{GP}_{y \rightarrow x}$ とは，入力空間 y から潜在変数空間 x のガウス過程に基づく確率モデルとして表す．提案手法では，これら 3 つのガウス過程モデル $\mathcal{GP}_{x \rightarrow y}, \mathcal{GP}_{x \rightarrow z}, \mathcal{GP}_{y \rightarrow x}$ を同時に学習する．具体的には，以下の目的関数を $\mathbf{X}$ とハイパーパラメータについて最適化することに帰着する．

$$\mathcal{L} = \alpha_1 \mathcal{L}_{x \rightarrow y} + \alpha_2 \mathcal{L}_{x \rightarrow z} + \alpha_3 \mathcal{L}_{y \rightarrow x} \quad (22)$$

$$\mathcal{L}_{x \rightarrow z} = -\frac{1}{2} (\ln |\mathbf{K}_{xz}| + (\mathbf{z} - \bar{\boldsymbol{\mu}}_z)^T \mathbf{K}_{xz}^{-1} (\mathbf{z} - \bar{\boldsymbol{\mu}}_z)) \quad (23)$$

ここで， $\alpha_1, \alpha_2, \alpha_3$ は各コストの重みを決めるパラメータであり，どのガウス過程モデルを優先的に考慮するかを決めるパラメータである． $\bar{\boldsymbol{\mu}}_z$ は出力変数 z の平均である． $\mathcal{L}_{x \rightarrow y}$ は，式 (18) で与えられる． $\mathbf{K}_{xz}$ は，グラム行列であり，各要素は式 (4) で表される．また， $\mathcal{L}_{y \rightarrow x}$ は入力変数から潜在空間への GP モデル $\mathcal{GP}_{y \rightarrow x}$ ための目的関数であり，以下の式で表される．

$$\mathcal{L}_{y \rightarrow x} = \mathcal{L}_{r, y \rightarrow x} + \sum_i \ln \theta_i + \frac{1}{\sigma_d^2} \text{tr}(\mathbf{S}_{b, y \rightarrow x}^{-1} \mathbf{S}_{w, y \rightarrow x}) \quad (24)$$

$$\mathcal{L}_{r, y \rightarrow x} = \frac{D}{2} \ln |\mathbf{K}_{yx}| + \frac{1}{2} \text{tr}(\mathbf{K}_{yx}^{-1} \mathbf{x}_N \mathbf{x}_N^T) \quad (25)$$

$$K_{yx, ij} = \theta_1 \exp \left(-\frac{\theta_2}{2} \|\mathbf{y}_i - \mathbf{y}_j\|^2 \right) + \theta_3 + \frac{\delta_{\mathbf{y}_i, \mathbf{y}_j}}{\theta_4} \quad (26)$$

$$\mathbf{S}_{b, y \rightarrow x} = \sum_{l=1}^L \frac{N_l}{N} \left[\frac{1}{N_l} \sum_{l=1}^{N_l} (\mathbf{y}_k^{(l)} - \mathbf{M}_{y_l})(\mathbf{y}_k^{(l)} - \mathbf{M}_{y_l})^T \right] \quad (27)$$




図 5: 予測時のグラフィカルモデル

$$\mathbf{S}_{w,y \rightarrow x} = \sum_{l=1}^L \frac{N_l}{N} (\mathbf{M}_{y_l} - \mathbf{M}_{y_0})(\mathbf{M}_{y_l} - \mathbf{M}_{y_0})^T \quad (28)$$

ここで、 σ_d^2 は第三項に対する重みパラメータであり、値を小さくするほどクラス間距離を大きく、クラス内分散を小さくため、D-GPLVM による影響を大きく受ける．反対に σ_d^2 を十分大きく設定すると、GPLVM のような振る舞いになる．グラム行列 $\mathbf{K}_{yx}$ の各要素である $K_{yx_{ij}}$ は式 (20) によって表される． $\theta_1, \dots, \theta_4$ はハイパーパラメータ、 $\mathbf{Y}_k^{(l)} = [\mathbf{y}_1^{(l)}, \dots, \mathbf{y}_{N_l}^{(l)}]^T$ はクラスラベル l を持つ入力変数の集合、 $\mathbf{M}_{y_l}$ はクラスラベル l を持つ入力変数の平均、 $\mathbf{M}_{y_0}$ は全ての平均である．

2.2.3 予測ステップ

予測ステップでは、学習ステップによって学習を行ったそれぞれの確率モデルを用いて、未知のセンサ入力に対する出力の確率分布を求める．予測ステップにおけるグラフィカルモデルを図 5 に示す．ここでは、学習ステップによって最適化されたモデルを用いて予測を行う．新しい入力を $\mathbf{y}_*$ 、それに対する潜在変数を $\mathbf{x}_*$ 、出力を z_* とする．予測ステップにおいては、出力の確率分布 $p(z_* | \mathbf{y}_*)$ は以下の式

(29) に示す周辺化によって求めることができる．

$$p(z_*|\mathbf{y}_*) = \int p(z_*|\mathbf{x}_*)p(\mathbf{x}_*|\mathbf{y}_*)d\mathbf{x}_* \quad (29)$$

しかしながら，式 (29) は未知の入力 $\mathbf{y}_*$ に対して，まず $p(\mathbf{x}_*|\mathbf{y}_*)$ の計算を行い，その分布の結果を用いて $p(z_*|\mathbf{x}_*)$ を計算する 2 段の確率モデルとなっているため，解析的に解くことが難しいという問題がある．そこで，本研究ではモーメントマッチングによる近似計算法 [30] によって出力変数の確率分布 $p(z_*|\boldsymbol{\mu}_{x*}, \boldsymbol{\Sigma}_{x*}) = \mathcal{N}(z_*|\mu_{z*}, \sigma_{z*}^2)$ の平均 μ_{z*} と分散 σ_{z*}^2 を求める．これにより， $\mathcal{GP}_{y \rightarrow x}$ の平均ベクトル $\boldsymbol{\mu}_{x*}$ と共分散行列 $\boldsymbol{\Sigma}_{x*}$ を $\mathcal{GP}_{x \rightarrow z}$ の平均 μ_{z*} と分散 σ_{z*}^2 に伝播する．

まず，新しい入力 $\mathbf{y}_*$ が与えられたとき，潜在空間の確率分布 $p(\mathbf{x}_*)$ の平均 $\boldsymbol{\mu}_{x*}$ と分散 $\boldsymbol{\Sigma}_{x*}$ は以下ようになる．

$$\boldsymbol{\mu}_{x*} = \boldsymbol{\mu}_x + \mathbf{x}_N^T \mathbf{K}_{yx}^{-1} \mathbf{k}_{yx_*} \quad (30)$$

$$\boldsymbol{\Sigma}_{x*} = \text{diag}(\mathbf{k}_{yx_*} - \mathbf{k}_{yx_*}^T \mathbf{K}_{yx}^{-1} \mathbf{k}_{yx_*}) \quad (31)$$

ここで， $\boldsymbol{\mu}_x$ は訓練データにおける潜在変数の平均である．また， $\mathbf{k}_{yx_*}$ は式 (4) によって示されるカーネル関数を用いた $k(\mathbf{X}, \mathbf{x}_*)$ によって表される縦ベクトルである．得られた潜在空間の平均と分散を時間予測の分散に考慮するために，近似計算法を用いる．

入力データから得られた潜在空間の平均と分散を用いて，予測の確率分布 $p(z_*|\boldsymbol{\mu}_{x*}, \sigma_{x*}^2)$ の平均 μ_* と分散 σ_*^2 は以下のように表せる．

$$\mu_* = (\mathbf{K}_{SE} + \sigma_\epsilon^2 \mathbf{I})^{-1} \mathbf{z}_N \mathbf{1} = \boldsymbol{\beta}^T \mathbf{1} \quad (32)$$

$$\sigma_*^2 = \boldsymbol{\beta}^T \tilde{\mathbf{L}} \boldsymbol{\beta} + \alpha^2 - \text{tr}((\mathbf{K}_{SE} + \sigma_\epsilon^2 \mathbf{I})^{-1} \tilde{\mathbf{L}}) - \mu_*^2 \quad (33)$$

ここで， σ_ϵ^2 は観測時に出力値に加わるノイズである．また， $\mathbf{K}_{SE}$ の各要素 K_{SEij} は以下の式 (34) のカーネル関数によって求められる．

$$k_{SE}(\mathbf{x}_i, \mathbf{x}_j) = \alpha^2 \exp \left(-\frac{1}{2} (\mathbf{x}_i - \mathbf{x}_j)^T \boldsymbol{\Lambda}^{-1} (\mathbf{x}_i - \mathbf{x}_j) \right) \quad (34)$$

ここで， $\boldsymbol{\Lambda}$ は対角行列， α^2 は分散パラメータである．また， $\mathbf{1} = [l_1, \dots, l_N]^T$ の

要素 l_i , $\tilde{\mathbf{L}}$ の要素は $\tilde{L}_{ij}$ はそれぞれ以下のように表せる.

$$l_i = \alpha^2 |\boldsymbol{\sigma}_{x*}^2 \boldsymbol{\Lambda}^{-1} + \mathbf{I}|^{-\frac{1}{2}} \times \exp \left(-\frac{1}{2} (\mathbf{x}_i - \boldsymbol{\mu}_{x*})^T (\boldsymbol{\sigma}_{x*}^2 + \boldsymbol{\Lambda})^{-1} (\mathbf{x}_i - \boldsymbol{\mu}_{x*}) \right) \quad (35)$$

$$\tilde{L}_{ij} = \frac{k_{xz}(\mathbf{x}_i, \boldsymbol{\mu}_{x*}) k_{xz}(\mathbf{x}_j, \boldsymbol{\mu}_{x*})}{|2\boldsymbol{\sigma}_{x*}^2 \boldsymbol{\Lambda}^{-1} + \mathbf{I}|^{\frac{1}{2}}} \times \exp \left((\tilde{\mathbf{w}}_{ij} - \boldsymbol{\mu}_{x*})^T (\boldsymbol{\sigma}_{x*}^2 + \frac{1}{2} \boldsymbol{\Lambda})^{-1} \boldsymbol{\sigma}_{x*}^2 \boldsymbol{\Lambda}^{-1} (\tilde{\mathbf{w}}_{ij} - \boldsymbol{\mu}_{x*}) \right) \quad (36)$$

ここで, $\tilde{\mathbf{w}}_{ij} = \frac{1}{2}(\mathbf{x}_i + \mathbf{x}_j)$ である. よって, 入力データ $\mathbf{y}$ から, 潜在空間 $\mathbf{x}$ を経て, 予測 z への平均と分散の伝播が可能となる.

第 3 章 起立動作意図予測への適用

本章では，人の日常生活における基本動作の 1 つである椅子からの起立動作を対象として，筋電位信号などのセンサデータから，離座時間がいつ発生するのかを予測する問題を考える（図 6 参照）．実際に想定する起立支援ロボットの実験環境（図 7 参照）より得られたセンサデータを用いて，提案手法による予測性能の有効性を確認する．

3.1 実験の目的

本実験では，提案手法による予測性能の有効性を確認する．ここでは，提案手法と 1) 中間層を持たないモデル，2) 判別的でない中間層を持つモデル，3) 判別に特化した中間層を持つモデルの 3 種類の手法との比較を目的とする．未知の起立動作のセンサデータより予測した起立時間と実際の起立時間との誤差による比較と，未知の起立動作と非対象動作との予測分散の差による比較の 2 つの比較を行う．

3.2 実験データ

本実験では，椅子からの起立動作（図 8 参照）と，2 種類の非対象動作を含むデータから，起立時間を予測する実験を行う．非対象動作は，着座姿勢から上半身を前に倒す動作を非対象動作 1（図 9 参照），着座状態のまま足踏みを行う動作を非対象動作 2（図 10 参照）とする．合計 3 種類の動作を各被験者ごとに収集し，そのセンサデータを用いて予測器を生成する．また，本実験において筋電位を計測する部位は大腿直筋，外側広筋，内側広筋，腓腹筋，前脛骨筋の 5 つの筋肉であり，図 11 に示す．以上の各脚 5 つの筋肉に対する筋電位（合計 10 次元）と，9 軸のモーションセンサの値（9 次元）より，入力次元は 19 次元である．

前述した 5 つの筋肉に対する筋電位を計測するために合計 10 チャンネルの筋電計を両脚に貼り付け，計測中に外れないようにサポータで覆う．また，腰の中心部分に 9 軸のモーションセンサを取り付けて加速度や角加速度を計測する．さらに，垂直方向の圧力を測定するフォースプレートを座面に設置し計測する．計測開始時




図 6: センサ情報からの起立時間予測




図 7: 実験環境




図 8: 椅子からの起立動作




図 9: 上半身を前に倒す動作（非対象動作 1）




図 10: 足踏みを行う動作（非対象動作 2）

にトリガ信号を用いて全てのセンサの時系列を同期させる．収集するデータは，サンプリング周期が 1000[Hz] の 10 チャンネルの筋電計から得られた時系列データと，サンプリング周期が 100[Hz] の腰に取り付けられた 9 軸のモーションセンサの時系列データである．筋電位信号とモーションセンサの周期を合わせるために，筋電位信号については 100[ms] (100 点) 毎に二乗平均平方根 (root mean square : RMS) を計算した値，モーションセンサの値については 100[ms] (10 点) 毎の平均を計算した値を用いる．これらの処理を行った後の実際の各動作に対する入力信号を図 12 に示す．赤線で示すのが筋電位信号，青線で示すのがモーションセンサの






図 11: 筋電位の計測部位


値となっている。起立動作に対する時系列データの収集には、7 秒毎に起立動作と着座動作を交互に動作を被験者に行ってもらいデータを収集した。非対象動作に対する時系列データの収集には、7 秒毎に着座姿勢から上半身を前に倒す動作、あるいは着座状態のまま足踏みを行う動作を被験者に行ってもらいデータを収集した。収集したデータの被験者数は 5 人であり、1 人あたり 3 種類の動作をそれぞれ 10 試行を行ってもらいデータを収集した。1 試行あたり 1 秒間のデータであり間隔は 0.1 秒間隔（計 10 点/試行）である。



(a) 起立動作



(b) 非対象動作 1



(c) 非対象動作 2

図 12: 入力信号

3.3 予測器の設定

本実験では、比較対象として提案手法と中間層を持たないモデル、判別的でない中間層を持つモデル、判別に特化した中間層を持つモデルを用意し比較する。1) 中間層を持たないモデルには入力層から直接予測を行う単純なガウス過程回帰を用いる（以下、NLS: Non-Latent Space と記述）。2) 判別的でない中間層を持つモデルには、ガウス過程を用いた次元削減の手法の 1 つである GPLVM によって生成した中間層を持つモデルを用いる（以下、GPLVM と記述）。3) 判別に特化した中間層を持つモデルには、線形識別しやすいような中間層を生成する手法の 1 つである LDA によって生成した中間層を持つモデルを用いる（以下、LDA と記述）。

実験データは、各被験者各動作 1 試行を訓練データとし、残りをテストデータとして評価する。本実験において、潜在空間を持つ手法の潜在空間の次元数は可視化のため 2 次元とした。また、中間層を持たない手法の訓練データは起立動作のデータのみを用いて学習を行った。提案手法の式 (18) のパラメータ σ_d を 0.04, 式 (22) のパラメータ $\alpha_1, \alpha_2, \alpha_3$ をそれぞれ 1, 2, 2 と設定し、最大の学習更新回数を 20 として matlab2014b 内の関数である fminunc を用いて準ニュートン法により最適化を行った。

3.4 実験結果

まず、ある一回の学習過程による目的関数の結果を図 13 に示す。横軸が更新回数、縦軸は目的関数の値となっており、更新回数が進むにつれて、目的関数が小さくなっていくのが分かる。

各手法による 2 次元の潜在空間の結果を図 14 に示す。赤丸で示すのが起立動作、青の三角マークで示すのが前に屈む動作、緑の四角マークで示すのが足踏みを行う動作に対する潜在変数の値である。提案手法は潜在空間において、各クラスごとに分かれているような潜在変数を持っていることが分かる。

次に実際の出力結果の一例を図 15 に示す。図中の左側である図 15(a), 15(c), 15(e), 15(g) は、未知の起立動作に対する入力データから各時刻において予測を行った結果である。横軸は離座時間までの時刻、縦軸は各時刻において予測された時間を示しており、黒の点線で示すのが真値である。図中の右側である図 15(b),




図 13: 学習の進行結果

15(d), 15(f), 15(h) は、未知の非対象動作に対する入力データから各時刻において予測を行った結果である。横軸は時刻、縦軸は各時刻において予測された時間である。図 15(a), 15(b) に示すのが提案手法による結果、図 15(c), 15(d) に示すのが比較手法（NLS）による結果、図 15(e), 15(f) に示すのが比較手法（GPLVM）による結果、図 15(g), 15(h) に示すのが比較手法（LDA）による結果である。各図内において、塗りつぶしてあるのが、各時刻における予測分散であり、塗りつぶされた幅が広いほど出力の不確かさが大きいことを表している。図 15 より、起立動作に対する予測結果として、提案手法が最も真値に近い予測をしている。また非対象動作に対しては、提案手法は対象動作に比べて予測分散が大きい出力をしている。

また、各時刻における予測誤差を示した結果を図 16 に示す。横軸は離座が発生するまでの真の時間、縦軸は各時刻において予測した離座発生時間である。赤で示すのは提案手法、青で示すのが比較手法（NLS）、緑で示すのが比較手法（GPLVM）、黄色で示すのが比較手法（LDA）による結果である。また、提案手法の予測誤差を 1 としたとき、各手法の予測誤差の比を示したものを図 17 に示す。図 16, 17 の結果より、提案手法の予測誤差が最も小さいことが分かる。

さらに、時間予測の分散について各動作の予測分散の平均を表 1 に示す。起立動作については全試行各時刻の予測分散の平均をとったものである。非対象動作に対




図 14: 生成された特徴量空間

する予測結果については，全試行各時刻のうち，0.5[s] から 0[s] の間を予測時間として出力したときの予測分散の平均をとったものである．また，起立動作と非対象動作の比をとったものを判別率とし，表の右端に示す．この結果より，提案手法が最も判別率が高いといえる．

3.5 考察

中間層における潜在空間について考える．中間層における潜在空間においては，提案手法と判別に特化した手法がそれぞれの動作ごとに分かれている．提案手法の中間層における潜在空間が動作ごとに分かれている理由は，目的関数とした式 (24) の

表 1: 各動作に対する予測分散


Variance	Sit-to-Stand	Leaning Forward (Non-Target1)	Stamping (Non-Target2)	Variance Ratio
Proposed	0.024	0.024	0.025	1.002
Comparison1 (NLS)	0.034	0.026	0.025	0.748
Comparison2 (GPLVM)	0.041	0.040	0.040	0.972
Comparison3 (LDA)	0.063	0.062	0.061	0.971

右辺第三項の影響であると考えられる。一方、判別的でない手法では異なる動作の潜在変数が混在している部分があることが分かる。


また、提案手法は判別に特化した手法に比べて、起立動作に対する潜在変数が潜在空間上に広く散らばっており、非対象動作に対する潜在変数の広がり比べて大きい。潜在空間上に広く点在しているということは、この潜在変数を用いて行う離座時間の予測が細かくできるといえる。つまり、時間予測を行う際に必要な情報量を保持できていると考えることができる。これは第2章に示したように同時学習を行った結果によるものであると考えられる。よって、中間層における潜在空間については、提案手法は時間予測に必要な情報を残しつつ、動作に判別的な潜在空間を生成できているといえる。

次に、離座時間予測の結果について考える。予測誤差は、図 16, 17 の結果から提案手法が最も誤差の小さい時間予測が行えるといえる。これは、動作に判別的かつ離座時間予測に適した中間層を持つ階層モデルにしたことにより、人の動作の多様性や観測ノイズによる悪影響を低減できたためであると考えられる。また、非対象動作に対する予測分散が大きくなった理由として、中間層において起立動作とは離れた位置に潜在変数が点在しているためだと考えられる。


以上のことから、提案手法は比較した手法の中において、最も予測誤差が小さく、非対象動作に対して判別的な予測を行うことのできる予測器であるといえる。




(a) 提案手法：起立動作




(b) 提案手法：非対象動作




(c) 比較手法（NLS）：起立動作




(d) 比較手法（NLS）：非対象動作




(e) 比較手法（GPLVM）：起立動作



(f) 比較手法（GPLVM）：非対象動作



(g) 比較手法（LDA）：起立動作



(h) 比較手法（LDA）：非対象動作

図 15: 各手法による出力結果




図 16: 起立時間予測の誤差




図 17: 予測誤差比




図 18: 起立支援ロボット

第 4 章 電動座椅子型ロボットを用いた起立支援応用

本章では，前章にて有効性を確認した提案手法を用いて実際に起立支援を行い，提案手法による起立支援性能について考える．

4.1 目的

前章より提案手法は最も予測誤差が小さく，予測分散が動作に判別的であることを示した．本実験では，提案手法によって予測された離座の発生時間と予測分散を用いて起立支援を行い，電動座椅子型ロボットの挙動と，起立支援効果について確認することを目的とする．

4.2 実験システムの構成

本実験では，図 18 のような座面が持ち上がる起立支援ロボットを用いる．リアルタイムで得られるセンサ値から実際に起立支援ロボットに制御信号が送られるまでの流れを図 19 に示す．図 19 より，予測を行う層が本研究の提案手法の部分である．提案手法では，対象動作と非対象動作との判別性を予測分散に考慮していることを示した．よって，本実験において，予測分散によって被験者が行おうとしてい




図 19: 信号の流れ

る動作が，対象の起立動作であるか非対象動作であるかを判断し，動作支援ロボットへの制御信号を決めるコントローラを設計する．設計したコントローラは提案手法による予測時間 $t[s]$ と予測分散 σ^2 を用いて以下の単純なアルゴリズムによって制御信号を出力する．本実験では，制御信号を電動座椅子型ロボットの出力トルクのゲインを決めるものとした．

出力パターンによるトルクの違いを図 20 に示す．マネキンの質量は錘を含めて $4.5 \times 10^3[g]$ である．図 20 より，パターン A はマネキンが勢いよく持ち上がるほどの出力であるのに対し，パターン B はマネキンが少し動くものの持ち上げるほどではない出力である．よって，予測分散の小さい予測に対しては力強く持ち上げるパターン A を出力し，予測分散が大きいものには起立支援を行わないパターン C



(a) パターン A による出力結果



(b) パターン B による出力結果

図 20: 出力パターンによる違い

を出力する．パターン A と C の間のやや紛らわしい予測分散に関しては，弱い力による起立支援を行うこと（パターン B）により，万が一非対象動作を行っていたとしても強制的に持ち上げるほどではないため，安全に考慮しているといえる．また，起立動作であったとしてもまったく動かさないパターン C に比べれば起立支援が期待できると考えこのようなコントローラを設計した．

予測器は前章の実験により得られたものを用いた．学習に用いたデータは被験者 5 名の各動作 1 試行のセンサデータである．被験者 1 名に起立動作を 15 回，非対象動作をそれぞれ 10 回ずつ行ってもらい，そのときのセンサデータを計測した．

4.3 応用結果

まず，各動作各試行ごとに出力された制御信号の結果を表 2 に示す．

表 2 より，起立動作に対しては制御信号の出力はパターン AB が多く，起立支

Algorithm 1 Assist Robot Controller

```
1: repeat
2:    $t \leftarrow$  predicted time [ms] from proposed method
3:    $\sigma^2 \leftarrow$  variance of prediction from proposed method
4:   if  $t$  such that  $200 \leq t \leq 400$  then
5:     if  $\sigma^2$  such that  $\sigma^2 \leq 0.035$  then
6:       Output Motor Torque Gain = 1 (Pattern A)
7:     else if  $\sigma^2$  such that  $0.035 < \sigma^2 \leq 0.038$  then
8:       Output Motor Torque Gain = 0.3 (Pattern B)
9:     else
10:      Output Motor Torque Gain = 0 (Pattern C)
11:   end if
12: else
13:   Output Motor Torque Gain = 0 (Pattern C)
14: end if
15: until Output Motor Torque Gain = Pattern A or Pattern B
```

表 2: 制御信号の出力結果

	Sit-to-Stand	Leaning Forward (Non-Target1)	Stamping (Non-Target2)
Pattern A	8	0	0
Pattern B	1	0	0
Pattern C	6	10	10
Total	15	10	10

援を行っていることが分かる．また，非対象動作に対しては，制御信号の出力はパターン C が多く，起立とは異なる動作に対しては起立支援を行いにくいという結果が得られた．このことから提案手法によって動作に対して判別的な制御信号を生成できるといえる．

表 3: 制御信号と起立支援のタイミング

Try	1st	2nd	3rd	4th	5th	6th	7th	8th	9th	10th
Output Pattern	B	C	A	C	A	A	A	A	A	A
Force Rate[%]	72.2	-	14.4	-	0.3	98.0	46.5	93.2	71.2	91.4
Try	11th	12th	13th	14th	15th					
Output Pattern	C	C	A	C	C					
Force Rate[%]	-	-	0.1	-	-					

次に起立動作を行ったとき，各試行における制御信号のパターンと起立支援が開始された座面反力の割合を表 3 に示す．表 3 より，起立動作に対して支援が行われない試行はあるものの，おおよそ起立支援を行う出力をしているのが分かる．また，最大で座面反力の割合が 98% の早いタイミングから支援動作が開始していることを確認した．

4.4 考察

起立支援について考える．表 3 より試行によって起立支援を行うタイミングが異なっていることが分かる．起立支援が遅れる理由として予測器が出力する予測時間の誤差の影響が考えられる．ここで，すべての試行において起立時に使われる 3 つの筋肉（内側広筋，外側広筋，大腿直筋）の筋活動量を図 21 に示す．筋活動量は起立支援を行わなかったものを 100[%] として正規化したものを示している．図 21 より，起立支援を行わなかった動作に比べて平均の筋活動量が減っていることから，すべての試行の中にきちんと起立支援が行われているものが存在しているのがわかる．そこで，座面反力が 70[%] 以上の試行を適切なタイミングで起立支援を開始し




図 21: 筋活動量による起立支援効果 1




図 22: 筋活動量による起立支援効果 2

ているものとし，それらの試行において起立時に使われる 3 つの筋肉（内側広筋，外側広筋，大腿直筋）の筋活動量を図 22 に示す．筋活動量は起立支援を行わなかったものを 100[%] として正規化したものを示している．図 22 より，適切なタイミングにおいて起立支援を行ったときには筋電位が小さくなっており，起立支援が行われていることが分かる．

第5章 まとめと今後の課題

本研究では、本研究では、ガウス過程に基づいて、対象動作と非対象動作との判別性を有する確率的な動作意図予測器の設計手法を提案した。具体的には、センサ入力から動作意図を出力とするガウス過程モデルとして考え、対象動作と非対象動作について判別的な潜在特徴空間を中間層に持つ階層ガウス過程モデルを提案した。

また、提案した動作意図予測器の有効性を確認するために、人の日常生活における基本動作の一つである椅子からの起立動作を対象として、生体信号に基づいて起立動作がいつ発生するのかを予測する問題について考えた。提案手法により設計した動作意図予測器は、比較手法に比べて予測誤差が小さいことを確認した。また、中間層の学習に動作の判別性も考慮することによって、起立動作と非対象動作の違いを予測分散に考慮できることを確認した。これにより、非対象動作に対する誤った予測を回避した動作意図予測が行えることを示した。

さらに、提案手法により設計した動作予測器を電動座椅子型ロボットへ応用し、安全性を考慮した起立支援を行えることを確認した。また、起立動作に用いられる筋肉の筋電量が支援によって減少していることから、提案手法による起立支援効果を確認した。

今後の課題として、更なる予測精度の向上とそのための改善を目指す。また、被験者人数や非対象動作を増やした場合における評価実験や、学習パラメータのシステムティックな設計方法の検討、センサの取り付け位置誤差に関する見解などが挙げられる。さらに、動作支援コントローラのシステムティックな設計方法の検討が挙げられる。

謝辞

大学院の研究生生活にあたり，研究姿勢から研究生生活に至るまで様々な面でご指導・ご鞭撻を頂きました奈良先端科学技術大学院大学情報科学研究科知能システム制御研究室の杉本謙二教授に深く御礼申し上げます。

ご多忙の中，副指導教員を引き受けて頂き，ゼミナール発表の場において，実機実験に関する的確な質問・ご指導をして頂きましたロボティクス研究室の小笠原司教授に深く御礼申し上げます。

本研究を進めるにあたり，ガウス過程を始めとする本研究の基礎となる知識の伝授から，研究の進め方や論文の書き方，学会発表の仕方に至るまで熱心なご指導を賜りました。副指導教員として常に的確なサポートをして頂きました松原崇充准教授に改めて深く御礼申し上げます。

研究内容や発表資料に関して率直なご意見を頂いただけでなく，日常の何気ない会話や研究の合間の息抜きとしてテニスで一緒に汗を流すなど研究生生活をサポートして頂いた南裕樹客員准教授に深く感謝いたします。

着任早々，研究に関するご意見を頂きました小林泰介助教に深く感謝いたします。

ご多忙な業務の中，貴重な時間を議論する時間に割いていただき，研究に関する議論や数々の貴重な意見を頂きました。実機実験の段取りや起立支援プログラムの実装の仕方など，本研究の実機応用に関して多大なご尽力をして頂きましたヒューマンウェア工学研究室の小澤順教授と井上剛准教授，さらにパナソニック株式会社先端研究本部の皆さまに厚く御礼申し上げます。

また研究生生活の中において，学会出張の手続きなど事務作業を行って頂いた林英子さんと橋本洋子さんに感謝いたします。

そして大学院生活にあたり，時には優しく，時には厳しく面倒を見ていただき，現在も多方面でご活躍されている先輩方，研究生生活の辛いこと・楽しいことを共有して，切磋琢磨しあった研究室の個性豊かな同期，今後の活躍が期待される優秀な研究室の後輩に心より感謝いたします。

最後に，遠く離れた場所から学生生活を最後まで支えてくれた家族やモチベーションを上げてくれる友人，ならびに関わって頂いたすべての方々に心から感謝申し上げます。

参考文献

- [1] K. Kasaoka and Y. Sankai. Predictive control estimating operator's intention for stepping-up motion by exo-skeleton type power assist system HAL. In *Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Expanding the Societal Role of Robotics in the the Next Millennium*, Vol. 3, pp. 1578–1583 vol.3, 2001.
- [2] K. Sakita, K. Ogawara, S. Murakami, K. Kawamura, and K. Ikeuchi. Flexible cooperation between human and robot by interpreting human intention from gaze information. In *Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, Vol. 1, pp. 846–851 vol.1, 2004.
- [3] T. Inamura, I. Toshima, H. Tanie, and Y. Nakamura. Embodied Symbol Emergence Based on Mimesis Theory. *The International Journal of Robotics Research*, Vol. 23, No. 4-5, pp. 363–377, 2004.
- [4] S. Suzuki and F. Harashima. Estimation of operational intentions utilizing Self-Organizing Map with Bayes filtering. In *Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pp. 2249–2255, Oct 2010.
- [5] C. Loconsole, S. Dettori, A. Frisoli, C. A. Avizzano, and M. Bergamasco. An emg-based approach for on-line predicted torque control in robotic-assisted rehabilitation. In *Proceedings of IEEE Haptics Symposium (HAPTICS)*, pp. 181–186, Feb 2014.
- [6] 則次俊郎. 空気圧ゴム人工筋を用いたパワーアシストウェアの開発. 日本ロボット学会誌, Vol. 33, No. 4, pp. 222–227, 2015.
- [7] A. Tatai, C. Nakagawa, A. Shintani, and T. Ito. Estimation and Minimization of Body Load during Sit-to-Stand Movement for Rehabilitation. *Journal of System Design and Dynamics*, Vol. 7, No. 4, pp. 488–503, 2013.
- [8] Sharif Muhammad Taslim Reza, Norhafizan Ahmad, Imtiaz Ahmed Choudhury, and Raja Ariffin Raja Ghazilla. A fuzzy controller for lower limb

exoskeletons during sit-to-stand and stand-to-sit movement using wearable sensors. *Sensors*, Vol. 14, No. 3, pp. 4342–4363, 2014.

- [9] 金子誠喜. 起立動作指導のための身体の構えの目安. 埼玉理学療法, Vol. 4, No. 1, pp. 4–9, 1996.
- [10] O. Fukuda, T. Tsuji, M. Kaneko, and A. Otsuka. A human-assisting manipulator teleoperated by emg signals and arm motions. *IEEE Transactions on Robotics and Automation*, Vol. 19, No. 2, pp. 210–222, Apr 2003.
- [11] A. J. Schmid, O. Weede, and H. Worn. Proactive Robot Task Selection Given a Human Intention Estimate. In *Proceedings of the 16th IEEE International Symposium on Robot and Human Interactive Communication (RO-MAN)*, pp. 726–731, Aug 2007.
- [12] S. K. Banala, S. K. Agrawal, and J. P. Scholz. Active Leg Exoskeleton (ALEX) for Gait Rehabilitation of Motor-Impaired Patients. In *Proceedings of IEEE 10th International Conference on Rehabilitation Robotics*, pp. 401–407, June 2007.
- [13] T. Matsubara, A. Uchikata, and J. Morimoto. Spatio-temporal synchronization of periodic movements by style-phase adaptation: Application to biped walking. In *Proceedings of IEEE International Conference on Robotics and Automation (ICRA)*, pp. 524–530, May 2012.
- [14] C. H. Ko, K. Y. Young, Y. C. Huang, and S. K. Agrawal. Active and passive control of walk-assist robot for outdoor guidance. *IEEE/ASME Transactions on Mechatronics*, Vol. 18, No. 3, pp. 1211–1220, June 2013.
- [15] T. Matsubara, D. Uto, T. Noda, T. Teramae, and J. Morimoto. Style-phase adaptation of human and humanoid biped walking patterns in real systems. In *Proceedings of IEEE-RAS International Conference on Humanoid Robots*, pp. 128–133, Nov 2014.
- [16] T. Matsubara, J. V. Miro, D. Tanaka, J. Poon, and K. Sugimoto. Sequential intention estimation of a mobility aid user for intelligent navigational assistance. In *Proceedings of the 24th IEEE International Symposium on Robot and Human Interactive Communication (RO-MAN)*, pp. 444–449,

Aug 2015.

- [17] S. S. Ge, Yanan Li, and Hongsheng He. Neural-network-based human intention estimation for physical human-robot interaction. In *Proceedings of the 8th International Conference on Ubiquitous Robots and Ambient Intelligence (URAI)*, pp. 390–395, Nov 2011.
- [18] K. Yamamoto, M. Ishii, K. Hyodo, T. Yoshimitsu, and T. Matsuo. Development of Power Assisting Suit. *JSME International Journal Series C Mechanical Systems, Machine Elements and Manufacturing*, Vol. 46, No. 3, pp. 923–930, 2003.
- [19] A. Tsukahara, R. Kawanishi, Y. Hasegawa, and Y. Sankai. Sit-to-Stand and Stand-to-Sit Transfer Support for Complete Paraplegic Patients with Robot Suit HAL. *Advanced Robotics*, Vol. 24, No. 11, pp. 1615–1638, 2010.
- [20] Y. Kato, T. Inoue, H. Motoyama, and J. Ozawa. Sit-to-Stand Intention Estimation Method Using the Angle of Forward Trunk Inclination and Leg Electromyograms. *IFAC-PapersOnLine*, Vol. 49, No. 19, pp. 261 – 265, 2016.
- [21] S. N. Yu, H. D. Lee, S. H. Lee, W. S. Kim, J. S. Han, and C. S. Han. Design of an Under-Actuated Exoskeleton System for Walking Assist While Load Carrying. *Advanced Robotics*, Vol. 26, No. 5-6, pp. 561–580, 2012.
- [22] H. Kawamoto and Y. Sankai. Power assist method based on Phase Sequence and muscle force condition for HAL. *Advanced Robotics*, Vol. 19, No. 7, pp. 717–734, 2005.
- [23] M. Yoshikawa, M. Mikawa, and K. Tanaka. A Myoelectric interface for robotic hand control using support vector machine. In *Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pp. 2723–2728, 2007.
- [24] T. Takeda, Y. Hirata, and K. Kosuge. Dance Step Estimation Method Based on HMM for Dance Partner Robot. *IEEE Transactions on Industrial Electronics*, Vol. 54, No. 2, pp. 699–706, April 2007.
- [25] N. Bu, M. Okamoto, and T. Tsuji. A Hybrid Motion Classification Ap-

- proach for EMG-Based Human-Robot Interfaces Using Bayesian and Neural Networks. *IEEE Transactions on Robotics*, Vol. 25, No. 3, pp. 502–511, June 2009.
- [26] C. M. Bishop. *Pattern Recognition and Machine Learning*. Springer, 2006.
 - [27] C. E. Rasmussen and C. K. I. Williams. *Gaussian Processes for Machine Learning*. MIT Press, 2006.
 - [28] N. D. Lawrence. Gaussian Process Latent Variable Models for Visualisation of High Dimensional Data. In *Proceedings of the Neural Information Processing Systems (NIPS)*, pp. 329–336, 2003.
 - [29] U. Raquel and D. Trevor. Discriminative Gaussian Process Latent Variable Model for Classification. In *Proceedings of the 24th International Conference on Machine Learning (ICML-07)*, pp. 927–934, 2007.
 - [30] M. P. Deisenroth, M. F. Huber, and U. D. Hanebeck. Analytic Moment-based Gaussian Process Filtering. In *Proceedings of the 26th International Conference on Machine Learning (ICML-09)*, pp. 225–232, 2009.
 - [31] 小林亨. 簡素化を目的とした筋電義手の開発. 法政大学大学院紀要 理工学・工学研究科編, Vol. 55, , 2014.

付録

A Toy Problem の擬似入力について

節 2.1.5 において，取り扱った擬似入力について説明する．ここでは，30 次元の入力空間を考えており，3 クラスの入力データとなっている．ある 1 次元空間に各クラスの平均を表す代表値 (x_{L1}, x_{L2}, x_{L3}) を定義する．ここで， x_{Li} はクラス i の代表値である．各クラスの擬似入力ベクトルを $\mathbf{y}_{L1}, \mathbf{y}_{L2}, \mathbf{y}_{L3} \in \Re^{30}$ として，以下の式 (37) により擬似入力ベクトルを生成した．

$$\mathbf{y}_{Li} = x_{Li}\boldsymbol{\sigma}_{Li} \quad (37)$$

ここで， $\boldsymbol{\sigma}_{Li} \in \Re^{30}$ はクラス i のノイズを示しており，その要素は正規分布による乱数による値となっている．ノイズを生成する乱数の分散値と，各クラスの代表値を与えることによって，各クラスごとに暗に分かれている入力ベクトルを生成していることになる．トレーニングデータの生成は入力ベクトルにさらにガウスノイズを加えることにより生成した．

B 起立動作

本研究では，椅子からの起立動作を動作支援の対象タスクとするため起立動作について説明する．椅子からの起立動作を図 23 に示す．まず椅子に着座した状態から始まり，上体を前傾させ自重の重心を前方へ移動させる．重心の移動に伴って身体を上方に持ち上げ，直立姿勢まで滑らかに移動する．




図 23: 椅子からの起立動作

C 筋電位信号

本研究では、入力信号として表面筋電位信号 (sEMG : surface electromyography) を用いて実験を行う。そのため、筋電位について説明する。

人間が身体を動かす際には、随意運動と不随意運動の 2 種類がある。不随意運動は主に脳からの信号ではなく意思とは無関係に生じる運動である。一方、随意運動は脳からの信号をもとに動作を行う運動である [31]。本研究の対象タスクである起立動作は随意運動である。随意運動は脳から信号が送られ、脊髄中の α 運動ニューロンが興奮すると、興奮信号が筋繊維に伝わる。筋繊維に信号が伝わると科学伝達物質が放出され、筋繊維に電位が発生する。これが筋電位である (図 24 参照)。筋電位によって筋肉の収縮が発生し、人間は運動を行っている。本研究では筋表面の電位信号である表面筋電位を用いて実験を行う。筋電位は筋収縮を発生させるものであり、収縮した結果として発生するものではない。よって、動作の発生前に得られる情報であるため、動作予測に適している信号の 1 つであるといえる。

表面筋電位は数十 [μV] から数 [mV] の変化しかないのでオペアンプなどを用いて信号を増幅したものが用いられる。また、表面筋電位は個人の筋肉量や脂肪量、電極との接触面などの影響を受けるため、非常に多くの雑音を含んだ信号である。




図 24: 筋電位信号

D 起立支援応用の追加結果

起立支援応用実験において、設計したコントローラは電動座椅子型ロボットの出力トルクのゲインを決めるものとした。このとき各出力パターンにおける筋活動量を図 25 に示す。図 25 はある被験者の各パターンによる支援を行ったときの代表的な筋活動量である。横軸は起立動作時に主に使われる筋肉の部位であり、縦軸は全く支援を行わなかったときの筋活動量を 100% として正規化したものである。図 25 より、支援を行うことにより筋活動量が減少していることが分かる。

また、本論文の 4.3 節において、提案手法のみの結果を示している。ここでは、すべての手法に対する出力結果を表 4 から表 7 に示す。ここでは本論文と同様に、3 章の実験により得られた予測器を用いた。すべての被験者の各動作 1 試行を学習データとし、ある被験者のデータ（起立動作 15 試行、非対象動作各 10 試行）をテストデータとした結果である。表 6, 7 の結果より、比較手法（GPLVM）と（LDA）はすべてパターン C の出力であるため、うまく支援を行えていないことが分かる。また、表 4, 5 の結果より提案手法と比較手法（NLS）は起立動作に対して支援を行うパターン A あるいは B を多く出力している。しかしながら、比較手法（NLS）は非対象動作に対してもパターン A の出力を行っていることが分かる。よって提案手法は危険な支援を実行する回数が減少していることが分かる。




図 25: 出力トルクの各パターンにおける筋活動量

表 4: 提案手法による制御信号の出力結果

	Sit-to-Stand	Leaning Forward (Non-Target1)	Stamping (Non-Target2)
Pattern A	53.3%	0%	0%
Pattern B	6.7%	0%	0%
Pattern C	40.0%	100%	100%

表 5: 比較手法 (NLS) による制御信号の出力結果

	Sit-to-Stand	Leaning Forward (Non-Target1)	Stamping (Non-Target2)
Pattern A	66.7%	70%	80%
Pattern B	13.3%	0%	0%
Pattern C	20.0%	30%	20%

表 6: 比較手法 (GPLVM) による制御信号の出力結果

	Sit-to-Stand	Leaning Forward (Non-Target1)	Stamping (Non-Target2)
Pattern A	0%	0%	0%
Pattern B	0%	0%	0%
Pattern C	100%	100%	100%

表 7: 比較手法 (LDA) による制御信号の出力結果

	Sit-to-Stand	Leaning Forward (Non-Target1)	Stamping (Non-Target2)
Pattern A	0%	0%	0%
Pattern B	0%	0%	0%
Pattern C	100%	100%	100%