

修士論文

運転者と車両の意図を力覚で紹介する運転支援 —ハンドル操作系列に基づくモデル生成方法—



平成29年度

三重大学大学院 工学研究科 機械工学専攻

益川 勇貴

目次

第1章	はじめに	1
1.1	研究背景	2
1.2	関連研究	3
1.2.1	車両の運転支援システム	3
1.2.2	本研究と従来研究の比較	5
第2章	提案手法	7
2.1	提案手法概略	8
第3章	実験	13
3.1	実験環境	14
3.1.1	車両への適応手法	14
3.1.2	システム構成	14
3.1.3	操作対象物	15
3.1.4	条件	17
3.2	一操作系列からの学習実験	18
3.2.1	モデルと適合度式の条件	18
3.2.2	課題発見と解決	19
3.3	提案手法からなるモデルの操作支援実験	22
3.3.1	提案手法からなるモデルの操作支援の結果	23
3.3.2	提案手法からなるモデルの操作支援の考察	25
3.4	更新回数を考慮したモデルでの操作支援実験	26

3.4.1	更新回数を考慮したモデルでの操作支援の結果	27
3.4.2	更新回数を考慮したモデルでの操作支援の考察	28
3.5	モデル作成の力覚ありなし比較実験	29
3.5.1	区別しない操作での比較	29
3.5.2	区別する操作での比較	31
3.5.3	モデル作成の比較でのまとめ	34
第4章	おわりに	36
	付録	37
	参考文献	47
	謝辞	50

目次

1.1	Google Car	2
1.2	The Developed Advanced Safety Vehicle (ASV)	4
1.3	Parallel Parking	5
2.1	The insignificant and significant operations	8
2.2	Algorithm for the proposed method (NS chart)	9
2.3	Left-to-Right HMM	10
2.4	Ergodic HMM	10
2.5	Model selection method	11
2.6	Average transition of likelihood	12
3.1	System structure	14
3.2	The small robot is named MieC	15
3.3	G27 Racing Wheel	16
3.4	Environment experiment	17
3.5	Transition of likelihood sequences	19
3.6	Transition a goodness of fit based on $P = \frac{l_{cur}}{l_{ref}}$	20
3.7	Transition a goodness of fit based on $P = \frac{K}{\sqrt{2\pi}\sigma} \exp(-\frac{(x)^2}{2\sigma^2})$	21
3.8	The model is generated from operation of every a certain distance	21
3.9	The generated model treats straight operation as silent state	22

3.10 The Operating sequences of subjects with high success rate for proposed system	24
3.11 The Operating sequences of subjects with high success rate for ordinary system	25
3.12 The average number of models created for each success	30
3.13 The environmental measurement and plot point (a whole and two) of the laser respectively	33
3.14 Relationship between the measurement distance of both angle by LRF and travel distance	33
4.1 Turning method of the car	42
4.2 Long-term relationship and Pivot turn	42
4.3 The relation between steering wheel and tire of cutting angle	43
4.4 Definition of the speed direction	44
4.5 Environment of experiment for measuring torque	45
4.6 The relationship between set value of force and torque	45

第1章

はじめに

人の機械に対する操作系列から人の操作意図が読み取れるものとし、それを元に人への操作支援する。このとき、機械から人に力覚提示する。力覚提示が人の望んだものでなければ、望んでいる操作ではないと機械に力覚提示する。これは、力覚を用いた人と機械のコミュニケーションである。

具体的には、本手法は、人の操作系列を隠れマルコフモデル（以下 HMM）で表現できるものとして考え、人の回りの状況と操作系列を機械が自動で学習し、回りの状況において類似した操作系列が与えられたとき、次の操作を機械が予測し人に力覚提示する。人の操作をお手本として力覚提示するので、熟練者が操作に慣れていない人に操作の仕方を教えることになる。具体例を挙げると自動車学校の教員の代わりをすることができる。また機械が学習したモデルを力覚提示し、それを人が正しいのか力覚で伝えるので、機械学習に応用できる。様々な機械操作において慣れが必要な操作手順を要するものが多く存在している。このような操作を簡単にすることができる。本研究の目的は、機械側のモデル学習と人側の操作学習の二つ存在する。機械側では、力覚提示により意味のある分類をすることで、人に適したモデルを作成することを目的とする。人側では、慣れが必要な操作に対し機械の操作を簡単にそして操作向上に繋がることを目的とする。これらの目的を達成するために、人と機械がコミュニケーションを取りながら人と機械が互いに学習していくシステムを提案する。本手法

は、系列において操作する機械すべてに適応できると考えている。ここでは本手法の有効性を示すために車両の運転操作を取り上げる。

1.1 研究背景

2017年の交通事故で亡くなった方は3694人であった[1]。原因としては速度超過や脇見運転など人の不注意が目立つ。運転操作を機械に委ねて人の不注意が入り込む余地を機械に置き換えていけば、交通事故も減少できる。そのため近年車両の安全技術は飛躍的に向上している。日本でもTOYOTA、日産、HONDAなどで様々な半自動運転技術が世に出てきている。また、グーグルではハンドルやアクセル、ブレーキの操作をしなくても道路を走る自動運転を目指している (Fig.1.1)。2017年頃から実用化されている半自動運転は、主に高速道



Fig. 1.1 Google Car

<http://japanese.engadget.com/2014/12/22/google-self/>

路または渋滞時などの限定された場面にしか対応していない。この場合運転の操作の主権と責任は人にある。その次の目標である自動運転では、操作の主権はシステムに移る。一見半自動運転の方が技術的に簡単だと考えられるかもしれない。しかし実際は、すべてにおいて半自動運転の方が技術的に簡単ではない。そこで半自動運転と自動運転のそれぞれの技術的に難しい点を述べていく。自動運転は半自動運転に比べて、整備された環境においては、システムが車両を制御するので、繰り返し精度が非常に高い。運転経路を決定するには、道の真ん中を通りさえすればいいので、運転者の意図を考慮する必要が無い。しかし半自動運転は運

転者が運転に介在するので、繰り返し精度が自動運転に比べ低い。そこで運転者の運転を推定し、適した運転経路を導く。運転者とシステムが協調しながら運転をしなければならないので、運転者の意図を考慮する必要がある。自動運転は運転者の意図を考慮する必要性がなく、半自動運転は考慮する必要があるので、この点に関して半自動運転の方が技術的に難しい。半自動運転は自動運転に比べて、複雑な道路状況（工事中や人が通るような状況）において、自動運転は運転者が運転の判断をしないので、どのような運転が正しいのか判断するのが難しい。しかし半自動運転では、運転者が基本的な運転の指針を決めてそれに基づいてシステムが支援がするので、比較的簡単である。このように半自動運転と自動運転それぞれに技術的に難しいのが異なる。半自動運転から自動運転に移行するために複雑な道路状況に対して、人が判断したモデルを作成する必要がある。そこで半自動運転で操作を補助しながら、人の判断からモデルを作成していく方法を提案する。

1.2 関連研究

本研究は手順の要する機械操作に適応できると考えているが今回は車両について取り上げているので、車両の運転システムについて述べる。そして本研究の違いを述べる。また本研究の要素部分を従来研究と比較して異なる部分を明確にする。

1.2.1 車両の運転支援システム

実用化されている ASV (Advanced Safety Vehicle) の技術を Fig.1.2 示す。市販車両には ACC (Adaptive Cruise Control) をはじめ、自動停止システムである衝突被害軽減ブレーキ (衝突回避支援システム)、操舵を制御して車線を維持する車線維持支援システム、走行時の車線からの逸脱を警告する車線逸脱警報システムなどドライバーの運転操作を自動化するさまざまな運転支援システムがすでに装備されている [2]。これらの技術は系列ではなく状況のみから判断して運転支援している。このことに関して Fig.1.2 中のレーンキープアシストを例に挙げて説明する。車線を認識し車両がその車線を越えた場合、ステアリングに力

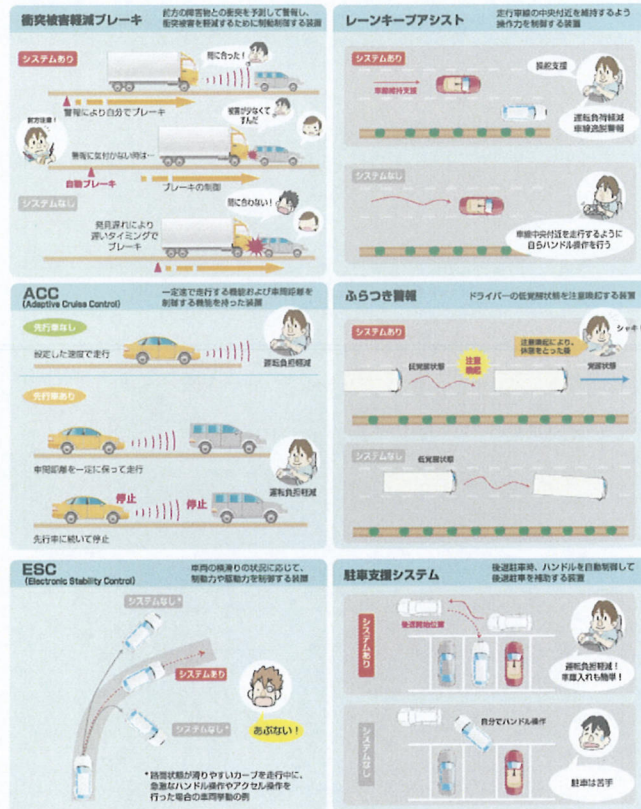


Fig. 1.2 The Developed Advanced Safety Vehicle (ASV)

<http://www.mlit.go.jp/jidosha/anzen/01asv/japanese/practical.html>

覚を与え車線に戻す。他の従来のシステムも同様に状況によりシステムが作動することを意味する。本研究では、状況はもちろんのこと系列からの判断も必要であると考えた。系列からの判断とは、ある一定の手順を必要とする操作である。系列からの判断がない場合は同じような場面でも違う操作をしているときに対応することができない場合が存在する。縦列駐車時を例に挙げ説明する。Fig.1.3を見たときに人は、車両が駐車されるのか駐車場から出庫していくのか区別がつかない。しかし、車両の進んでいた系列を知ることが出来れば、どちらの操作がされるか区別がつくであろう。このように人の操作意図は、事前事象（過去の操作）によりその後の操作の確率に変化するものである。このことを利用して操作を予測できると考えた。




Fig. 1.3 Parallel Parking

1.2.2 本研究と従来研究の比較

本研究は、四つの側面を持つ。具体的には以下に明記する。

- (i) 操作の推定,
- (ii) ハンドルを介しての力覚提示,
- (iii) 操作の分類,
- (iv) モデル学習

本提案手法との比較として、運転支援の従来研究を四つの側面から紹介する。

操作の推定では、運転者の操作に対して、HMM を改良し、操作の推定精度を向上させる研究がされている [3],[4]。また HMM を使用し、意図しない車線逸脱を予測する研究がされている [5]。しかしこれらの研究では、予測するだけであるが本研究では、推定したものを運転者に力覚提示して、運転支援する。

力覚提示は、車両が計画された経路に追従するように誘導する研究がされている [6],[7],[8],[9]。これらの研究では、経路作成を物理法則的や bezier 曲線を利用している。これらの方法で作成された経路は、燃費等に関して理想的であるが、運転者に必ずしも適しているとは言えない。それは運転者の自身の意図が反映されていないからである。そこで本手法では、運転者が実際にした操作を経路とした。これにより運転者に適した経路が作成されると考えた。

分類では、交通状況に依存した操作や車線変更に対して、得られたデータを使い、統計的に設定した閾値により自動的に識別する研究がされている [10],[11],[12],[13]。この方法は、人があらかじめデータに対して、クラスと正解ラベルを付ける必要がある。操作のクラスを決定する際に正しいクラス数が選択されているとは限らない。そこで本手法では、操作のクラス数を決めず、車両が力覚提示する操作に対して運転者の反応に応じクラス数を決定していく。これにより運転者が区別する必要があるなしを考えて操作の適切なクラス数を決めることができる。

モデル学習では、大量のデータを収集し、それらを分類し、ラベルを付けて学習する研究がされている [14],[15],[16]。しかしこれらは意味のある分類がされていない可能性がある。そこで本研究では、学習結果を力覚提示により伝えられ、運転者はその学習が正しいかどうか確認していく。つまり本手法は運転者と車両が同時に操作方法を学習して、お互いに確認することで、意味のある分類をしていく。

また本研究室では、前任者が操作の予測からの力覚提示することを提案し、力覚提示することで操作に関しての有効性と HMM から操作を予測することができるか二つに分けて検証した [17]。そして 2015 年に自身の卒業論文で、HMM から操作を予測して、力覚提示することで操作にどのような影響を与えるか検証した [18]。

ここまで本研究に関して、四つの側面と本研究室の取り組みについて述べてきた。我々は、操作しやすい運転を力覚を介して伝えるために (iv) モデル学習に特に焦点を当てて報告する。

第 2 章

提案手法

本提案手法は、力覚を介することで、運転者が用意されたモデルと区別する必要の無い操作と区別する必要のある操作を考慮しながらモデルを作成する手法である。また自身の運転方法をシステムが学習することで、個々間の癖を考慮することができると考えている。

意味のない操作と意味のある操作を Fig.2.1 に示す。この Fig.2.1 中の実線、破線はそれぞれ区別しない操作、区別する操作を示している。また左側は理想的なモデル作成がされている例である。円で囲まれているのは、その操作系列をまとめてモデルを作成している。ここでなぜ右側のモデルが理想的でないのかについて説明する。

Case one では経路に対して左折する操作を一つのモデルとして作成する必要がある。これは一つの操作に対して複数のモデルを用意する必要がないためである。しかし右側では区別する必要がないにも関わらず複数のモデルとして作成されている。つまり区別する必要がない操作から新しいモデルを生成している。

Case other では障害物があるので、モデルを区別する必要がある操作から二つのモデルを作成する必要がある。しかし右側では区別する必要があるにも関わらず、一つのモデルとして作成されている。つまり区別する必要がある操作から新しいモデルが生成されていない。

本手法ではこれらのような場合において区別する必要があるかないかを考慮してモデル作成していく。これにより運転者に適した操作を力覚提示できると考えた。




Fig. 2.1 The insignificant and significant operations

2.1 提案手法概略

本研究は機械操作の操作系列と機械の周囲の環境値を観測することで、その次の操作入力を推定し、それに合う入力を人に力覚提示するシステムを製作し評価するものである。人が過去にした操作である参照操作系列と現在の操作系列を比較し、適合度を算出することで次の操作を推定し、人に機械が判断した結果を力覚提示することで伝える。伝えられる力覚提示の強さは、適合度に依存している。これにより操作に強弱が生まれ、操作の重要度が明確になると考えた。より強く力覚提示される操作は、繰り返された回数が多く重要である可能性が高いと考えられる。つまり力覚提示が強い場合は、重要度が高い操作を示し、逆に力覚提示が弱い場合は、重要度が低い操作を示す。力覚提示に対して、人が自身の意図と同じであると判断すれば、力覚提示に従い操作する。また人が自身の意図と違うと判断すれば、自身のしたい操作をシステムに伝える。操作終了後にシステムが人の意図を理解できた場合は、その際選択されたモデルにデータを加えてパラメータを更新する。操作終了後にシステ

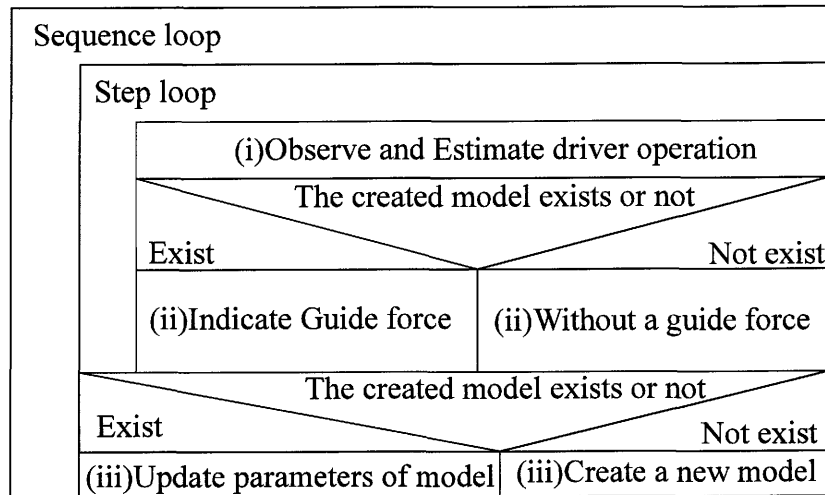


Fig. 2.2 Algorithm for the proposed method (NS chart)

ムが人の意図を理解できない場合は、これまでにモデル化されていないものとし、その際のデータを使い新たなモデルを生成する。システムが人の意図を理解できない場合は、力覚提示はされない。つまりシステムを使う度にモデルの更新か生成がされる。本手法はシステムを使いながら、作成した経路を力覚提示することで、人の意図を確認し、データを分類していく。それにより意味づけられた分類が可能になると考えた。

この提案手法を NS チャートで表すと Fig.2.2 のようになる。ここで詳しく NS チャートについて説明していく。

(i) Observe and Estimate driver's operation:

人の操作系列が多い場合はいくつかに分類しておく。学習する際は、隠れマルコフモデル (以下 HMM) を使う。HMM は系列学習ができ、よく音声認識に使用される。また行動認識にも使われている。簡単に HMM について説明すると入力値としてある系列を与えて学習する。そうするとそのモデルに対して遷移確率モデルを与えてくれる。HMM から得られる遷移確率状態には大きく分けて Left-to-Right HMM と Ergodic HMM が存在する。Left-to-Right HMM は、必ず状態を左から右に遷移するため、次の状態に遷移すると前の状態に戻ることができない。また、Ergodic HMM は次の状

態に遷移しても前の状態に戻ることが可能なモデルである. Fig.2.3 に Left-to-Right HMM の一例を示す. Fig.2.4 に Ergodic HMM の一例を示す. 円は, 状態を示している. Ergodic HMM では, モデルの自由度が高いため EM アルゴリズムの一種である




Fig. 2.3 Left-to-Right HMM




Fig. 2.4 Ergodic HMM

Baum-Welch(付録の 1 に記載する)などの局所探索法では, 初期値に依存し豊富な局所解に捕らわれてしまう問題がある. 本研究では, 局所解に陥りにくい Left-to-Right HMM を使う. 通常 HMM では時系列に対して学習する, だが時間に依存しないような操作例えば操作対象物以外が動かない場合は, 距離系列に変更することで, パラメータを減らすことができる. ここで減らすことができるパラメータは速度である. つまり通常は時間ごとに操作系列を取り出すが, 距離ごとに操作系列を取り出す. 学習したモデルから操作を推定する方法は, 得られた操作系列をモデルに与えその過去の操作系列との尤度を算出する. その尤度に基づいて適合度を算出する. 尤度と適合度は学習したモデルの数だけ算出される. その中で最も大きな適合度を持つモデルを現在の操作とする. このことを Fig.2.5 に示す. Fig.2.5 では, 二つのモデルを学習している. Fig.2.5 の上部は参照系列を示している. まず適合度を比較する. この例での適合度は 0.8 と 0.002 である. 大きい方 0.8 を閾値と比較する. ここでは, 閾値を 0.03 に設定している. 今回の例では, 閾値を越えているので, モデルは存在しているとなる. もし閾値を越えないのならモデルは存在していないとなる.

(ii) Indicate guide force and Without a guide force:

(i) による人の操作の観測と推定からモデルが存在している際は, モデルと同様な操作




Fig. 2.5 Model selection method

を人に力覚提示する。力覚提示する式は以下のようになる。

$$E = targetA - A \quad (2.1)$$

$$force = (K_P E + K_I \int_0^t E dt) \times P \quad (2.2)$$

E:偏差,force:力覚 [N・m], K_P :比例定数,targetA:目標値,A:現在の値, K_I :積分定数,P:尤度に基づく適合度である。

力覚提示される経路は、そのモデルを生成するのに使用した操作系列を使用する。具体的に尤度を計算する方法は、現在時刻までの系列から Viterbi アルゴリズム（付録の 2 に記載する）で最尤モデルを選択する。経路を人に力覚提示する際に、操作系列が離散的なデータなので、補間する必要がある。補間しないときれいな軌跡を描くことはできない。補間する方法として今回はスプライン補間を使用する。

Fig.2.6 には、対数尤度と基本量によるステップの関係を示す。式 (2.2) に示す通り力覚提示する際に尤度に基づいた適合度を乗算する。これにより尤度に応じた力覚を人に伝えることができる。Fig.2.6 はステップ数が大きくなると減少する。この原因は二つある。一つは、操作系列が入る度にその操作の確率を乗算する。そのためステップが長くなればなるほど小さくなる。二つは、選択されうる操作が複数あるときは大きく減少する。これは選択されうる操作の確率の合計が 1 になるためである。一の要因に関しては、補正しないと操作系列が入る度に力覚の大きさが下がるので、力覚提示

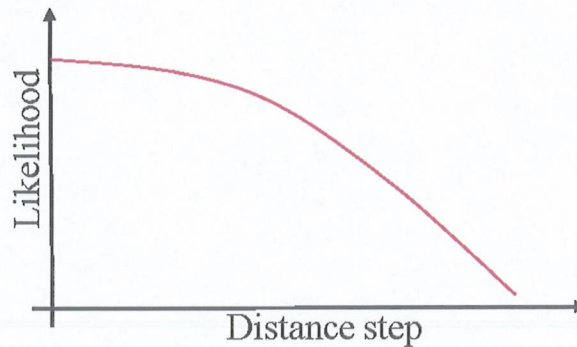


Fig. 2.6 Average transition of likelihood

する際に力覚の低下を補正する必要がある。

(i) による人の操作の観測と推定からモデルが存在しない際は、人に力覚提示しない。再度人は自身のしたい操作を伝えることで、モデルが存在していると判断されれば力覚提示される。しかしモデルが存在しないと判断されている限り、人に力覚提示されることはない。

(iii) Update parameters of model and Create a new model:

操作終了後にシステムが人の意図を理解できた場合は、その際選択されたモデルにデータを加えてパラメータを更新する。パラメータを更新することは、データをそのモデルを生成したデータ群に加えてHMMを使い学習させていくことを示す。少ないデータからでもこのシステムを使うことで、認識率を上げることができる。操作終了後にシステムが人の意図を理解できない場合は、これまでにモデル化されていないものとし、その際のデータを使いHMMを使い新たなモデルを生成する。これにより今までは区別する操作をあらかじめ決定していたが、人が運転しながら区別する必要がある操作を決定していく。そのためあらかじめ区別する操作数を示すクラス数を決めておく必要性がない。しかし本手法では、現在は閾値を設定している。人と機械との間の力覚で自動的に閾値を設定できる可能性がある。

第3章

実験

これまで本研究室では、モデルを作るために、複数の操作系列を使い学習させていた。その結果から認識し、人に対して力覚提示し、操作の補助をしてきた。実験により Fig.2.2 のモデルのパラメータ更新と新しい操作モデルの学習以外について実現の可能性を示した [18]。

本論文では、モデルのパラメータ更新と新しいモデルの生成について有効である可能性を示す。これが適用できればあらかじめクラス数を決定せずに、操作しながら必要に応じてクラス数を決めながらモデルを作成できると考えた。モデルのパラメータ更新をすることで、学習データが収集でき、モデルの汎化能力を上げることができる。新しいモデルの作成では、学習していたモデルが一つでも人がシステムを使うことで、操作中に観測している操作系列を人が力覚提示を通じて、分類していくことで、モデルを増やすことができる。しかし新しいモデルの学習では、一つのデータから生成する必要がある。これは未学習のモデルの区別を付けることが出来ないためである。そこで一操作系列からの学習実験では、一操作系列で作成したモデルではどのような問題が発生するか確かめ、その対処方法を述べていく。実験では、モデルのパラメータ更新と新しいモデルの学習についての有効である可能性を示すために二つの検証をした。

3.1 実験環境

ここでは一操作系列からの学習実験，モデル作成の比較実験，本提案手法からなるモデルの操作支援で共通の適用例，システム構成，車両代替，条件について述べていく。

3.1.1 車両への適応手法

本提案手法を車両への操作に適応する。車両が操作される環境は，操作対象物以外も時間で環境が刻一刻と変化するので，操作系列は時間系列となる。また，車両は操作対象物以外時間変化がなくとも静的に環境が変化するので，環境値を考慮する必要がある。また，Human Machine Interface（以下 HMI）はハンドルであるので観測するものはハンドル角度，速度，環境値である。

3.1.2 システム構成

本論文の実験では，ハンドル，ペダル，操作対象物を使用する。システム構成は，Fig.3.1で示される。ハンドル，ペダルはコンピュータに USB で接続されている。また操作対象物

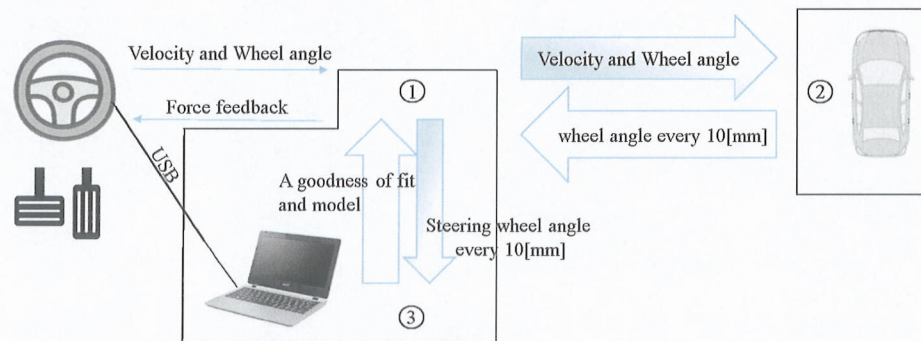


Fig. 3.1 System structure

にもコンピュータが搭載されている。操作対象物はソケット通信により情報のやり取りをしている。Fig.3.1で示される1から3はプログラムを示している。矢印は，各プログラムの

データのやり取りをしている。太い矢印で表されているのは、ソケット通信でのやり取りを示している。1のプログラムがサーバーで2のプログラムがクライアントである。各プログラムの流れを説明する。プログラム1は、ハンドルとペダルから操作指令を受け取り、MieCに伝える。2のプログラムは操作対象物から10[mm]ごとのハンドル角度値を受け取り、3のプログラムに伝える。3のプログラムはそのハンドル角度値を分類する。その後適合度を算出し、現在している操作のモデルを選択する。そして1のプログラムに適合度とモデルを伝える。1は受信した適合度とモデルに応じた力覚提示をハンドルから人に伝える。この時力覚提示の力の設定をプログラム上で経験則的に最大0.8までとした。トルクに換算すると0.96[N・m]である。この換算はFig.4.6を使用している。プログラム3ではHMMが算出する尤度に基づいた適合度を算出する。その際ライブラリ：GHMM 0.9-rc3, プログラムコード:python2.7,Os:linux Debian Jessieを使用した。使用したノートパソコンは、SSDでcorei7である。

3.1.3 操作対象物



Fig. 3.2 The small robot is named MieC

本論文の実験には、ロボット MieC(Fig.3.2)を操作対象物として使う。MieCは三重大学機械工学科メカトロニクス研究室で制作されたロボットである。MieCの進行方向を正面とすると寸法は縦180[mm], 横160[mm]である。移動機構として車両とMieCでは違いがあ

るので、車両の代用品として MieC をそのまま使用することはできない。これは MieC がクローラー機構であるのが要因である。この違いを無くす必要がある（付録の3記載する）。実機に接続している Laser Range Finder（以下 LRF）は取り外しが可能である。

また実機を操作するための HMI はハンドルでの形で force feedback できるものを選択する必要がある。そこで、Logitech の G27(Fig.3.3) を HMI として採用する。G27 は -450° ～



Fig. 3.3 G27 Racing Wheel

450° 回転する。これは実際の車両のハンドル角度に近いものである。HMM で学習するのに G27 のハンドル角度を使い学習する。G27 の最大トルクは $2.3[N \cdot m]$ である。ハンドルの直径は $0.28[m]$ である。ハンドル角度ごとに操作を分類して、隠れマルコフモデル (HMM) を学習させるのはできない。分類方法を式 (3.1) で示す。

$$n = \text{sign}(\text{angle})\text{floor} \times \frac{\log |\text{angle}|/a}{\log r} \quad (3.1)$$

angle:分類される角度 $[\circ]$, a:初項, r:公比, n:分類数となる。この分類方法は、中心のハンドル角度に重きを置いている。各パラメータは $a = 5, r = 1.901, n = -6 \sim 6$ とした。実際のハンドル角度と分類の関係は、Table.3.1 で表される。Table.3.1 は時計回りのみを示すものである。Table.3.1 で示すとおり、中心ほど角度の幅が狭く中心から離れるほど角度の幅が広くなるように設定した。また、力覚に対してどの程度のトルク $[Nm]$ が出力されるか検証した。これはプログラム上で force feedback の値を設定することしかできないためである（付録の4記載する）。

Table 3.1 The allocation table for steering wheel angle

Class	0	1	2	3	4	5	6
Steering wheel angle	~9.5	~18	~35	~65	~124	~236	~450

3.1.4 条件

本論文の実験環境を Fig.3.4 に示す。実験環境は、壁に模擬した三角コーンと障害物を設




Fig. 3.4 Environment experiment

置した。これらに衝突せずに操作し、ゴールである赤線まで到達できた回数を成功回数とした。実験環境では、二つの経路を持つ。一つ目は、Fig.3.4 中で黄緑で表されているように左の壁に沿う形で左折する経路である。二つ目は、Fig.3.4 中で緑で表されているように右の壁に沿う形で左折する経路である。各実験において使用する経路が異なる。実験と使用する環境の対応を Tab.3.2 に示す。今回は本手法の有効性を示すために車両を取り上げたが環境値については考慮していない。また操作対象以外は時間に対しての変化のない空間を用意した。速度も低速として操作系列は時間系列でなく距離系列とするので、速度のパラメータを無視する。またモデルのありなしを判定するための閾値は 0.03 に設定した。これは経験

Table 3.2 The correspondence experiments to routes in environment

Previous experiment	Trun left along wall of right
Operability of generated model	Turn left along wall of lef
Genaration of model from significant operation	Both turn left along wall of right and left

則的に決定されている。今回の適応先は狭い路地等を想定している。実験では HMM で学習する際に、試行回数を削減するために、急ハンドルをさける指示や一定方向にしかハンドルを切るのみに制限した。

3.2 一操作系列からの学習実験

一操作系列からの学習実験は、一操作系列で学習させたモデルではどのような問題が発生するか確かめ解決する。これは提案手法 Fig.2.2 のモデルの更新・作成が可能か検証するための実験である。一操作系列でモデルを学習させる必要があるのは、未学習間での分類ができないためである。詳しく述べると学習したモデルを基準として、現在の操作が学習済みか未学習かを判断することは可能である。しかし未学習同士では、基準が存在しないので、区別することができない。そのため一操作系列での学習をする必要がある。本研究室 [18] では、複数の系列から学習させて操作の補助をしていたので、今回一操作系列で学習させたモデルからの補助で生じる問題を発見し対策する。

3.2.1 モデルと適合度式の条件

モデルの作成方法は、10[mm] ごとのハンドル角度の系列を操作系列とした。操作系列から HMM に基づきモデルを生成する。そのモデルを生成するために使用した操作系列を与えて参照尤度系列を用意した。また現在操作中の操作系列をモデルに与えて尤度を算出する。

モデルが選択される際はこの尤度が高いものを現在の操作のモデルと推定した。その後参照尤度系列と操作の距離ごとに算出される尤度（尤度系列）を使い適合度を算出する。力覚提示に乗算する適合度を式 (3.2) に示す。

$$P = \frac{l_{cur}}{l_{ref}} \quad (3.2)$$

l_{ref} は現在の操作と比較する参照尤度系列である。 l_{cur} は現在操作中の尤度系列である。尤度系列は前章で述べたが系列数に応じて低下していく。そこで式 (3.2) のように適合度を表現することで、対策した。

3.2.2 課題発見と解決

基準となるモデルは、一操作系列から生成した。その後4回同じ操作をした。モデルに使用した操作系列の対数尤度系列（参照尤度系列）と4回の対数尤度系列を Fig.3.5 に示す。破




Fig. 3.5 Transition of likelihood sequences

線で表されているモデル生成に使用された操作系列の参照尤度系列である。実線が4回同じ操作をしたものの尤度系列の推移である。これまで [18] では、学習に使用する操作系列の中で最も大きな参照尤度系列を選択していた。その結果確率的に参照尤度系列よりも大きな値は現れなかった。しかし今回は学習に使用したのは一操作系列であるため Fig.3.5 で見られるように頻繁に参照尤度系列より大きな値を持つものが生じた。そのため力覚提示に乗算する適合度が 1 を超えることになる。 Fig.3.5 を適合度式 (3.2) に代入すると Fig.3.6 のように

なる。これにより力覚提示で過剰なトルクが出力され 0.8 を超えると操作の補助がされなく




Fig. 3.6 Transition a goodness of fit based on $P = \frac{l_{cur}}{l_{ref}}$

なる。そのため力覚提示により操作の補助をするために現在の適合度式 (3.2) では不適切である。適合度の式を以下のように変更した。

$$x = l_{ref} - l_{cur} \quad (3.3)$$

$$P = \frac{K}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x)^2}{2\sigma^2}\right) \quad (3.4)$$

K は適合度を最大 1 にするパラメータである。式 (3.4) は差分を評価するように変更した。そしてその差分が正規分布になると仮定している。つまりその差分のズレがどの程度出現しやすいかを示している。最後に K を乗算することで適合度の最大値が 1 になるように調節している。実際に式 (3.4) のように変更した適合度に Fig.3.5 を代入したものを Fig.3.7 に示す。Fig.3.7 を見ると適合度が 1 を超えることがないことが確認できた。

Fig.3.5, Fig.3.6, Fig.3.7 では、 x 軸は距離を示している。 x 軸の始めが 650[mm] からとしているのは、すべての操作系列が直進を示しており、 y 軸である尤度に差が出ないためである。直進している間は操作に変化が生じないので、必然的に尤度は高い。実際に Fig.3.5 でも参照尤度系列より高い尤度を持つ尤度系列は直進操作が長いことが確認できた。現在のモデルとして選択されるものは、尤度が高いものが選択される。つまり適したモデル選択ができない。これは研究室の取り組み [18] と分類の重きを変更したのが原因だと考えられる。[18] では、時計周りか反時計回りにハンドル操作していることと中心ほど重要なハンドル角

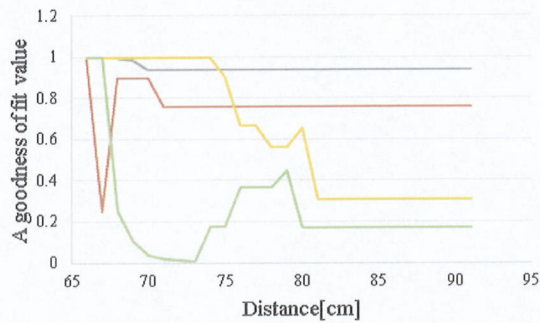


Fig. 3.7 Transition a goodness of fit based on $P = \frac{K}{\sqrt{2\pi\sigma}} \exp\left(-\frac{(x)^2}{2\sigma^2}\right)$

度としていた。つまりハンドル角度値 0° の際に 0 と分類されるのみである。ハンドル角度が 0° を示すことはないので、必然的に直進を示すのは、1, -1 の二つとなる。しかし一操作系列で学習する場合においては、初期位置のハンドル角度に依存して、同じ操作をしたとしても同じモデルだとみなされない。そのため Tab.3.1 のように変更した。過度に直進が強く学習される原因は、直進を示す系列が大量に操作系列に含まれるためである。その学習結果を Fig.3.8 で示す。Fig.3.8 では、縦の 0 から 5 が状態数を示している。横の -6 から 0 は出力

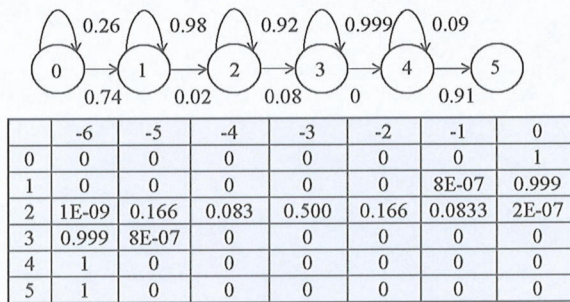


Fig. 3.8 The model is generated from operation of every a certain distance

シンボルを示している。状態 0 と 1 での出力シンボルが 1 を示しており、これらの状態では 1 の出力シンボルが選択される。そして状態 1 から状態 2 に遷移する確率が 0.02 と学習されている状態から直進が過度に学習されていることが確認できる。この問題を解決するために直進操作を示す 0 を音声認識での無音状態と考え、0 の出力シンボルを一つにまとめて学習

させた。その学習結果を Fig.3.9 に示す。Fig.3.9 では状態 0 で直進を示す出力シンボルが大




Fig. 3.9 The generated model treats straight operation as silent state

きくなるのを防ぐことが出来た。これにより直進を過剰に学習しないモデルを作成できた。

3.3 提案手法からなるモデルの操作支援実験

提案手法を使い操作しながらモデルを作成し、操作支援する方法の有効性を示す。このことを示すために以下の三つの方法と比較した。

本提案手法:操作しながらモデルを作成し、力覚提示

従来手法:あらかじめ用意されたモデルからの力覚提示

支援なし:操作を補助する力覚提示なし

提案手法と従来手法を比較することで、モデル作成においてあらかじめ用意するのではなく、操作しながらモデルを作成し支援する必要性を確認する。従来手法はあらかじめ熟練者が操作し、10回の成功データからモデルを作成しておく。これに対して提案手法は同じ10回の成功データを支援なしの10回の成功データからモデルを作成しておく。その後操作しながらその成功ごとにモデルの更新または生成する。提案手法と支援なしを比較することで、支援なしでの被験者の成功率が得られ、どの程度成功率が向上するのかを確認する。本来なら慣れによる影響を減らすために三つのグループを作り、方法に対しての順番を変える必要があるが二グループにしか分けることができない。グループは、(支援なし, 提案手法,

従来手法)と(従来手法, 支援なし, 提案手法)の二つである。これは提案手法と従来手法の学習回数を同条件で実験したいので, 提案手法を一番最初にできないためである。評価するのは経路に対する操作の成功率である。またアンケートを取り, どの方法が操作しやすいか調査した。使用する経路は左の壁に沿う形で左折する経路である。被験者数は20代男性5人である。

3.3.1 提案手法からなるモデルの操作支援の結果

それぞれ三つの方法での操作結果を Table.3.3 に示す。三つの方法の成功率に大きな差は

Table 3.3 Relationship between success rates and assistive systems

Assistive system	Proposed system	Ordinary system	System without assist
Success rate	0.675	0.668	0.693

見られなかった。そこで被験者ごとの成功率を二つに分けた。分け方は提案手法, 従来手法どちらが高い成功率を出したかである。このわけ方で提案手法では3人, 従来手法では2人に分かれた。提案手法で高い成功率を出した3人の三つの方法での操作結果を Table.3.4 に示す。Table.3.4 では10%以上提案手法は支援なしと比べて成功率が上昇している。この結

Table 3.4 The subjects that have higher success rate than ordinary system

Assistive system	Proposed system	Ordinary system	System without assist
Success rate	0.868	0.572	0.71

果が生じた理由としては, 被験者3人(提案手法)は従来手法でのハンドルを切るタイミングが大きく違うことが確認できた。また3人の間でも異なるタイミングでハンドル操作していた。このことを Fig.3.10 に示す。Fig.3.10 は提案手法で高い成功率を持つ被験者の操作系列と従来手法でモデルを生成するのに使用した操作系列を示している。大きくハンドルを切るタイミングが違うことで, 従来手法では力覚提示により誘導する前に異なる操作と認識

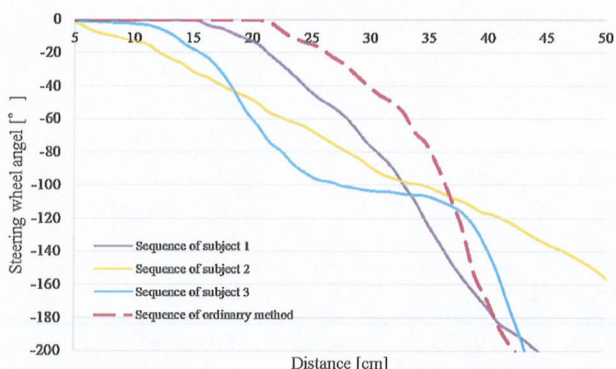


Fig. 3.10 The Operating sequences of subjects with high success rate for proposed system

し，操作を誘導できなかつた可能性がある。

従来手法で高い成功率を出した 2 人（従来手法）の三つの方法での操作結果を Tab.3.5 に示す。Tab.3.5 での従来手法の成功率は全体の成功率と比べて，提案手法は 20% 低下し，従

Table 3.5 The subjects that have higher success rate than the proposed system

Assistive system	Proposed system	Ordinary system	System without assist
Success rate	0.385	0.813	0.67

来手法では 15% 上昇している。この結果が生じた理由としては，被験者 2 人（従来手法）は力覚提示されるハンドルを切るタイミングとほとんど同じであると確認できた。このことを Fig.3.11 に示す。Fig.3.11 を見ると曲がりはじめがほとんど同じであるため被験者 2 人は力覚提示により正しく誘導されたと考えられる。本提案手法で正しく誘導されず成功率が低い理由としては，作成されたモデルに原因がある。これは複数のモデルが作成されたことである。複数のモデルが作成されると現在の操作を推定する際に，頻繁にモデルの切り替わりが生じた。また従来方法で同様なことが生じない理由は，モデルが一つしか作成されなかつたためである。

アンケート結果を Table.3.6 に示す。このアンケートは，三つの支援方法に関して実験後

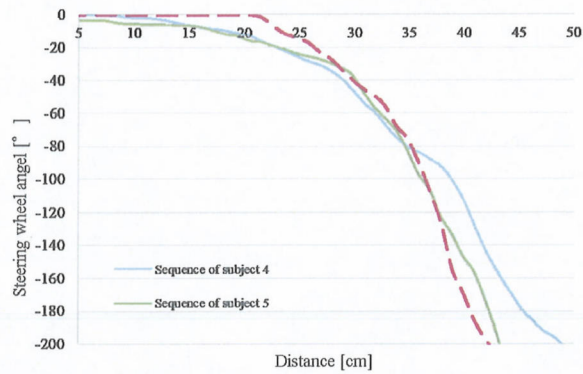


Fig. 3.11 The Operating sequences of subjects with high success rate for ordinary system

どの方法が最も操作しやすいと感じたか調査したものである。同程度の評価には、すべて選択させた。またなぜその回答をしたのかについても明記させた。多数明記されたものを紹介

Table 3.6 The questionnaire survey on which assistive system is easier to operate

Assistive system	Proposed system	Ordinary system	System without assist
The number of subjects	3	2	1

する。本提案システムが操作しやすいと感じた被験者は、力覚提示に従うことで成功できたと回答した。支援システムなしが操作しやすいと感じた被験者は、二つの支援システムありに対して、力覚提示の変わり目で違和感を感じたと回答した。従来システムが操作しやすいと感じた被験者は、力覚提示されるのが被験者自身の操作に近く操作しやすいと回答した。

3.3.2 提案手法からなるモデルの操作支援の考察

提案手法が操作しやすいか三つの方法を比較した。評価である成功率に明確な差は見られなかった。しかし提案手法と従来手法においてそれぞれで成功率が高い二つのグループに分

けた。その結果提案手法が操作性に関して有効である可能性があることを示した。またアンケート結果からも操作しやすいとの回答が最も多かった。複数のモデルが作成されると現在の操作を推定する際に、頻繁にモデルの切り替わるという課題が生じた。そのため力覚提示が操作を誘導するのではなく、外乱のように働いていたと考えられる。これがアンケートの結果でも挙げた力覚提示の変わり目での違和感であると考えられる。解決するために学習回数に応じて適合度が変化する必要がある。適合度を変化させるためにモデル間に重み関数を導入し、選択されるモデルの入れ替わり頻度を低下させる。変更するために重み関数に学習回数がある程度増えれば1に近づくシグモイド関数を利用する。その式を式(3.5)に示す。

$$W = \frac{1}{1 + e^{-0.65N}} \quad (3.5)$$

N, W はそれぞれモデルの更新回数、重み関数である。 -0.65 はモデルの更新回数が0であるとき約 $W = 0.65$ に調節されている。これ以上 W の値を下げると人が力覚を感じられなためである。また経験則的にモデル更新が5回された際に約 $W = 1$ になるように設定した。当然これらのパラメータは最適に設定されていない。適合度にこの重み関数を乗算し、更新回数を考慮した適合度を以降の実験では使用する。

3.4 更新回数を考慮したモデルでの操作支援実験

この実験では、提案手法からなるモデルの操作支援に更新回数を考慮した適合度において操作性にどのような影響を与えるか実験する。またグループを二つに分けて実験していた。しかし操作の補助なしのシステムは、グループの分け方により最後に検証されることはない。そのため慣れによる影響で操作の補助なしのシステムでは、成功率が低下しやすいと考えられる。そのため三つの方法を成功率に関して等しく扱うために、二つでなく三つのグループに分ける。三つのグループは(補助なし, 提案手法, 従来手法), (提案手法, 従来手法, 補助なし), (従来手法, 補助なし, 提案手法)である。被験者は6人, 20代の男女である。評価するのは、各方法の成功率である。アンケートを取りどの方法が操作しやすいか調査した。そして提案手法と従来手法でどちらがより現在の操作を推定して、力覚提示でき

ている確率と標準偏差を評価する。これは現在の操作を推定するモデルがどちらが適切であるか評価するためである。使用する経路は左の壁に沿う形で左折する経路である。

3.4.1 更新回数を考慮したモデルでの操作支援の結果

更新回数を重み関数に取り入れた提案手法と従来手法、支援なしの三つの方法での操作結果を Tab.3.7 に示す。Tab.3.7 の結果から提案手法は他の方法に比べて 10% 程度向上している

Table 3.7 Relationship between success rates and all systems considering weight function

Assistive system	Proposed system	Ordinary system	System without assist
Success rate	0.874	0.741	0.735

るのを確認した。またアンケート結果を Tab.3.8 に示す。このアンケートは、更新回数を考慮した三つの支援方法に関して、実験後どの方法が最も操作しやすいと感じたか調査したものである。同程度の評価には、すべて選択させた。またなぜその方法を選んだのかも調査した。Tab.3.8 では提案手法が最も操作しやすいと回答した被験者が多い。Tab.3.6 と比べて

Table 3.8 The questionnaire survey on which assistive system considering weight function is easier to operate

Assistive system	Proposed system	Ordinary system	System without assist
The number of subjects	3	1	2

提案手法が最も操作しやすいと選択した被験者は増加しなかった。提案手法以外で操作しやすいと回答した被験者は、力覚提示が有効に働く際もあるが確実に成功しないので、支援システムなしが最も操作しやすいと回答した。また従来手法を選択した被験者は、提案手法は成功ごとにモデルの更新または作成することで、システムが安定しないので自身の意図した方向と違う場合が存在したためと回答した。

また提案手法と従来手法でシステムが現在の操作を認識し、力覚を介してる割合を比較する。その結果を Table.3.9 に示す。従来手法では、力覚提示が働く確率が低く、また標準

Table 3.9 Relationship between working rate and standard deviation of guide force and two assistive systems

Assistive system	Proposed system	Ordinary system
The working rate of guide force	0.583	0.40
The standard deviation of guide force	1.34	3.11

偏差が大きく個々に依存していることが確認できた。本提案手法では、従来手法と比べ力覚提示が作動した確率が高く、また標準偏差が小さいことから個々に依存しないことが確認できた。

3.4.2 更新回数を考慮したモデルでの操作支援の考察

提案手法は他の方法と比較して、高い成功率を出した。このことから提案手法からなるモデルの操作支援で課題のモデル間の切り替わりを低下させるための重み関数が有効に作用したと考えられる。

アンケート調査で被験者は、力覚提示に従い失敗することもあるので、支援なしのシステムが最も操作しやすいと回答した。これに対してセンサ情報を取り入れることで、環境を理解し障害物に衝突しないように操作支援することで、解決可能であると考えている。また提案手法は成功のたびにモデルが更新または生成されるため、力覚提示の方法が試行回数ごとに変化する。そのため自身の意図した方向と違う場合が存在したためと回答したと考えられる。これに対して繰り返すことで、一回の成功の変化が少なくなることで低下すると考えられる。

提案手法と従来手法の力覚提示が作動した率とその標準偏差から提案手法の方が次の操作を推定するモデルが作成されているとともに個々に依存しないシステムであると考えられる。

3.5 モデル作成の力覚ありなし比較実験

この実験では本手法と従来手法のモデル作成の違いについて比較する。力覚提示を使う本手法は、随時運転者に区別する必要があるモデルかどうかを確認して作成する。従来方法は統計的に設けられた閾値に従いモデルを区別して作成する。従来手法では閾値を使いあらかじめ区別すべき操作を決めている。従来手法として力覚提示なしを使用する。しかしその区別すべきだと考えていた前提が違う場合は適切なモデルが作成されないと考えた。ここでは区別されない経路と区別される経路を用意し、作成されるモデルを評価した。

3.5.1 区別しない操作での比較

ここでは区別されない実験を取り上げる。Fig.3.4で示された実験環境中の左の壁に沿う経路を使用する。経路において変化がないので、モデルは理想的には一つになるはずである。しかし実際には学習データ数が少ないことや閾値が経験的に設定しており適切な値とは言えない。これらの理由から今回の理想的な一つのモデルにならない可能性がある。そのため区別する必要のない操作において新しいモデルとして生成する数がどちらが少ないか評価する。また区別する必要のない操作ではモデルは、一つのモデルに収束するためにモデルの更新回数が多くなるので、どちらが更新回数が多いか評価する。成功回数が20回に達するまで繰り返した。成功回数ごとにモデルの更新または新しいモデルの生成をする。被験者は20代の男性被験者5人である。慣れによる影響を減らすために5人の被験者を二つに分けた。モデル生成の実験結果をFig.3.12に示す。Fig.3.12は成功ごとの生成されたモデルの平均数を示している。赤線は本提案手法である力覚提示ありを示している。青線は従来方法である力覚提示なしを示している。 x 軸は成功回数で y 軸はモデル生成数である。この結果より常に力覚提示ありのシステムの方が変化のない環境や状況において、新たなモデルが生成されないことが確認できた。成功回数20回において力覚提示ありでは、平均で6個のモデルが生成された。また力覚提示なしでは、平均で7.2個のモデルが生成された。差としては、1.2しかない。しかしこれは大きな差であると考えられる。力覚提示ありのシステムは、初




Fig. 3.12 The average number of models created for each success

めの段階（成功回数が少ない場合）は、学習がほとんどされておらず、モデルが選択されない。そのため初めの段階では力覚提示なしと同条件である。差が生じるのは力覚提示のあるなしのみに依存する。差が生じたのは成功回数 10 回から生じたので、この成功回数を基準（モデルが共に 4.4 生成された）とすると約 43% 力覚提示ありのものがモデル生成を減少させることが確認できた。力覚提示ありのシステムの方がより区別する必要がないと認識しモデル作成できたと考えられる。

次に各被験者の更新されたモデルの最大回数の実験結果を Table.3.10 に示す。両システムそれぞれの実験において、被験者ごとの最大のモデル更新回数の合計値、平均、頻度を示す。Tab.3.10 から力覚提示ありのシステムの方がモデルの最大更新回数の合計が高いこと確認

Table 3.10 The number of maximum updating for both system

	The total number	The average number	Frequency
With guide force	47	9.4	0.47
Without guide force	38	7.6	0.38

できた。これはモデルの収束度合いが高いことを示している。この結果より力覚提示ありの方が運転者の考えが反映されたモデルを作成することができた。

これらの結果は力覚提示があることで誘導され、被験者はモデルと異なる操作をしなくなると考えられる。また区別しない操作に対して本提案手法は、従来方法に比べて区別する必要がないと認識し、モデル作成できることを示した。

3.5.2 区別する操作での比較

ここでは区別する操作の実験を取り上げる。Fig.3.4 で示された実験環境中の右の壁に沿う経路を使用する。左の壁に沿う経路を学習した後に、異なる意味を持つ操作をするので、モデルは理想的には別のモデルであると認識されるはずである。しかし左の壁に沿う経路のモデル数が多いと別のモデルであると認識されにくくなる。これは似たようなモデルが生成されるのが確率的に増加するためである。またこの実験でも学習データ数が少ないことや閾値が経験的に設定しており適切な値とは言えない。これらの理由より明確に別モデルとしてモデルが生成されないので、モデルの生成率を評価する。力覚提示ありなしの両システムを比較する。成功回数が3回に達するまで繰り返した。この実験では成功ごとにモデルの更新、作成をしない。これは初めて学習したモデルと異なる操作をした際に、新たなモデルが生成されるかを確認するためである。被験者は20代の男性被験者5人である。慣れによる影響を減らすために5人の被験者を二つに分けた。実験結果をTable.3.11に示す。これらはモデ

Table 3.11 Relationship between each probability of creating model and system

	With guide force	Without guide force
Learned model (a whole)	30/100=0.3	38/100=0.38
Learned model (from last to third)	1/15=0.067	3/15=0.2
Model for new route(a whole)	9/15=0.6	6/15=0.4

ルが生成される確率と学習した経路（全体）、学習した経路（最後から三番目まで）、別経路（全体）それぞれの関係を示している。本来は同程度学習が進んだ状態でのモデル生成確率を比較すると、別経路での新しいモデルの生成率が高いことが確認できた。また学習した経路（全体）と別経路でも比較すると、同様に別経路で新しいモデルの生成確率が高いと確認できた。このことから学習した経路と別経路は区別する必要がある。また別経路での力覚提示ありとなしを比較すると力覚提示ありの方が新しいモデルの生成確率が高いことが確認できた。

これらの結果は力覚提示により異なる操作に誘導されるので、運転者はそれに逆らうことで新しいモデルの生成確率が高くなったと考えられる。また力覚提示ありとなしのシステムでは、学習した経路においてモデル数が異なる。これは区別しない操作の実験で Fig.3.12 中に示している。モデル数が多いほど本来は区別されるべき経路でも学習した経路と誤認識される確率が高くなる。このことから学習した経路でモデル数の生成が少ない力覚提示ありのシステムの方が新しいモデルの生成率が高くなったと考えられる。また区別する操作に対して本提案手法は、従来方法に比べて区別する必要があると認識し、モデル作成できていることを示した。しかし学習した経路と別経路を完全に分離できなかった。これは別々のモデルが入り混じることになり、区別する必要があるものが区別できていないことを示す。このことに対して LRF (Laser Range Finder) 等のセンサで外部環境を認識することで解決することができると考えられる。

LRF を使用する区別する操作の分離

区別する操作では学習した経路と別経路を完全に分離することができなかった。そこで Fig.3.2 のように LRF を実機に取り付けることで、外部環境の情報を加える。外部情報を使用する上で北陽電機株式会社の LRF (URG-04LX-UG01) を使用する。測定範囲と角度分解能はそれぞれ 240° 、約 0.36° である。計測のレーザ本数は、約 666 本であるので、分類数を 2 としても処理回数が膨大になる。実際に処理回数を式 (3.6) に示す。

$$d = c^n \quad (3.6)$$

d は処理回数、 c は分類数、 n は 1 スキャンで得られるセンサの本数 (666)、分類数を 2 とすると処理回数は $d > 10^{200}$ になる。そのためリアルタイムで処理して、現在のモデルを推定できない。また HMM を使い得られた距離データ一つ一つを分類し、学習させることは計算量が大きくなり不可能である。少ないレーザの本数で学習する必要がある。そこで二本のレーザを使用する。Fig.3.13 に計測環境と全て、二本それぞれのレーザのプロット点を示す。Fig.3.4 で示した環境では、レーザ計測ができない。そこで LRF が最も計測しやすい白





Fig. 3.13 The environmental measurement and plot point (a whole and two) of the laser respectively

色の壁を用意した。二本のレーザのプロット点は $\pm 30^\circ$ とした。これは前方を見るために設定したに過ぎず、適切な角度ではない。レーザを一本でなく二本にしたのは、面を認識するためである。距離データはハンドル角度と同様に 10[mm] ごとに習得する。計測データを Fig.3.14 に示す。これらは各角度のレーザ点と移動距離の関係を示している。Fig.3.14 は、



(a)The measurement distance of 30°

(b)The measurement distance of -30°

Fig. 3.14 Relationship between the measurement distance of both angle by LRF and travel distance

左の壁に沿い左折する経路を操作して得られた結果である。左に示しているのが Fig.3.14 の

左側の壁に対応する。右に示しているのが Fig.3.14 の右側の壁に対応する。Fig.3.14 から左 (30°) のレーザの変化する計測距離は約 400[mm] である。Fig.3.14 から右 (-30°) のレーザの変化する計測距離は約 240[mm] である。また三回の計測結果が同様な傾向があることから安定した計測距離が得られると考えられる。この結果より $\pm 30^\circ$ のレーザ分割を Table.3.12 に示す。レーザの分割は実験環境で経験的に決めたものであるので、環境に応じ

Table 3.12 The allocation table for distance data by LRF

Class	1	2	3
Distance data by LRF	~245[mm]	~432[mm]	433[mm]~

て変更される必要がある。

この分割により得られるデータを使い式 (3.2) に代入することで、レーザに基づいた適合度を算出する。またこれまでのハンドル角度の系列から学習し、得られた過去に学習した系列と現在の系列のハンドル角度からなる適合度と LRF を使い計測した距離データから学習し、同様の LRF の距離からなる適合度は関係した事象なので、積算したものを統合適合度とする。この統合適合度を使用して実際に、被験者 1 人で学習した経路と異なる別経路に対して操作した結果分離率は 100% となった。しかしこの方法はモデル推定にしか LRF による距離データを使用していない。つまり LRF による環境に対する操作の修正はしていない。

3.5.3 モデル作成の比較でのまとめ

区別しない操作での比較では、区別しない操作つにおいて新しいモデルとして生成する数がどちらが少ないか評価した。また一つのモデルに収束するためにモデルの最大更新回数を評価した。そして本提案手法である力覚提示ありのシステムが従来手法である力覚提示なしのシステムより区別しない操作から新しいモデルとして生成する数が少ないことが確認できた。これは力覚提示があることで誘導され、被験者はモデル以外の操作をする必要性が少なくなったと考えられる。

区別する操作での比較では、区別する操作つまり区別する必要がある操作において新しいモデルが生成されやすいか評価した。その結果、別経路での力覚提示ありとなしを比較すると力覚提示ありの方が新しいモデルの生成確率が高いことが確認できた。力覚提示により異なる操作に誘導されるので、運転者はそれに逆らう。また、力覚提示ありとなしのシステムでは、学習した経路においてモデル数が異なる。これらの理由から新しいモデルが生成されやすくなったと考えられる。しかし力覚提示ありのシステムでも分離できなかった。そこで LRF を使い経路を正しく分離する方法を提案し、100% 分離できた。

これら二つの結果から本手法はモデル作成に関して、従来手法と比べて区別しない操作と区別する操作を考慮してモデル作成が可能である一例を示した。

第4章

おわりに

本論文では区別する必要がある操作と区別する必要のない操作を考慮してモデルを作成することを目的とした。また人の操作性の向上も目的とした。目的を達成するために人と機械がコミュニケーションを取りながら人と機械が互いに学習するための手法を提案した。その提案手法は、隠れマルコフモデル (HMM) から学習したモデルを使い次の操作を推定する。その推定をハンドルを介して力覚提示する。人はその力覚提示が自身の意図する操作か確認する。もし自身の意図する操作であるならば力覚提示に従い操作する。もし自身の意図する操作でなければ、自身の意図を再度伝える。操作終了後機械は推測結果が正しいと判断した場合、推測したモデルに操作系列を加えてモデルを更新する。操作終了後機械は推測結果が正しくないと判断した場合、得られた操作系列から新しいモデルを生成する。このように操作ごとにモデルの更新・生成する。そのため新しく生成されるモデルは一列のみで初めは学習される。

実験により提案手法中の一列の学習から正しいモデルが作成されるか確認した。確認方法はあらかじめ一列でモデルを生成した。その後同様の操作をする際に力覚提示が設定値を超えることと直進を強く学習する問題が生じた。これらの問題に対して、適合度の式と学習するためのデータの取り扱いを変更し、それにより一列での学習の問題を解決した。

人の操作性に関して提案手法が三つの方法を比較した。比較したのは、成功ごとにモデル

の更新・作成し支援する方法, 用意されたモデルから支援する方法, 支援なしである。これらの方法に差が生じなかった。原因は, モデルの切り替わり生じたので, モデルに学習回数から重みをつけることで, 提案手法が他の方法よりも操作性が良いことを示した。

モデル作成に対しての力覚ありなし比較実験した。比較したのは, 本提案手法である力覚提示を使い随時運転者に区別する必要があるか問う方法と閾値を使いあらかじめ区別する操作を決めている方法である。区別する必要がある操作とない操作の経路において両方で提案手法が優れていることを確認した。しかし理想的なモデル数とはならなかった。

これらから本提案手法は, 設定した目的の機械側と人側で有効である可能性を示した。現在は統計的に閾値を設けてデータを分類したり, ビッグデータを分類する方法があるが人が操作しながらデータを分類しモデルを作成する新しい方法を提案した。

今後の課題として経験則的に HMM の状態数, モデルの有無を分ける閾値, ハンドルの角度の分類, 学習回数を考慮した重み関数を決定していた。しかしこれらは環境に大きく依存するものである。そこで今後は操作した系列長や操作の複雑さからこれらのパラメータを自動で変更するシステムを導入する。またアンケートでは力覚提示に従い失敗することもあるので, LRF 等の外部センサを取り入れる。そして衝突することを防ぐような経路を導き力覚提示する。また実験では, 得られた生成されたモデル数, 成功率がどのような分布に従うという結果が得られるまで実験できていない。そこで被験者数を増やし, どのような分布に従うか検証し, その後有意差があるのか検定する。現在は車両の代わりに小型の移動体を使用しているが小型電気乗用車を使い, 実環境での違いを確認し解決する。

付録

1. Baum-Welch アルゴリズム

与えられた観測系列 $O=O_1O_2\cdots O_T$ から, Baum-Welch アルゴリズムで HMM のパラメータ $\lambda=(A,B,\pi)$ を推定するためのものである. 与えてあげるものは, 観測系列:観測されたシンボルの系列 $O=O_1O_2\cdots O_T$ である. 本研究では, 操作の入力値を観測系列としている. 求められるもの, $\lambda=(A,B,\pi)$ である. 補足すると遷移確率分布 A:状態 S_i から S_j へ遷移する確率 $a_{i,j}$, 観測シンボル確率分布 B:状態 S_j でシンボル v_K が出力される確率をシンボル出力確率 $b_j(K)$, 出力シンボル数を K , 初期状態分布 π :時刻 $t=1$ での状態 S_i にいる確率 π_i である. Left-to-Right HMM では, 初期状態分布確率は $\pi_0=1$ になる. Baum-Welch アルゴリズムでは forward アルゴリズムと backward アルゴリズムを利用する. forward アルゴリズムは, 時刻 t で状態 S_i にあり, その時刻までの系列を出力する確率である.

$$\alpha_1(i) = \pi_i b_i(O_1) \quad (4.1)$$

$$\alpha_{t+1}(j) = \sum_{i=1}^N \alpha_t(i) a_{i,j} b_j(O_{t+1}) \quad (4.2)$$

backward アルゴリズムは, forward アルゴリズムの逆の方向から計算する. つまり最終状態から, 初期状態に向かって計算する.

$$\beta_T(i) = 1 \quad (4.3)$$

$$\beta_t(i) = \sum_{j=1}^N a_{i,j} b_j(O_{t+1}) \beta_{t+1}(j) \quad (4.4)$$

次に $\xi_t(i, j)$ と $\gamma_t(i)$ の計算をする. $\xi_t(i, j)$ は, 時刻 t において状態 S_i から状態 S_j に遷移する確率である. $\gamma_t(i)$ は, 時刻 t において状態 S_i にいる確率である. これは, Forward アル

ゴリズムと Backword アルゴリズムの値を利用して計算する.

$$P(O|\lambda) = \sum_{i=1}^N \alpha_T(i) \quad (4.5)$$

$$\xi_t(i, j) = \frac{\alpha_t(i) a_{i,j} b_j(O_{t+1}) \beta_{t+1}(j)}{P(O|\lambda)} \quad (4.6)$$

$$\gamma_t(i) = \sum_{j=1}^N \xi_t(i, j) \quad (4.7)$$

次に、これらを用いてモデル $\lambda=(A,B,\pi)$ を更新する.

$$\pi_i = \gamma_1(i) \quad (4.8)$$

$$a_{i,j} = \frac{\sum_{t=1}^{T-1} \xi_t(i, j)}{\sum_{t=1}^{T-1} \gamma_t(i)} \quad (4.9)$$

$$b_j(K) = \frac{\sum_{t=1, s.t. O_t=v_K}^T \gamma_t(j)}{\sum_{t=1}^T \gamma_t(j)} \quad (4.10)$$

この計算を変化がなくなるまで繰り返すことによって最適なモデル λ を推定できる. Left-to-Right HMM では繰り返すが $\pi_0=1$ と決まっているので, 式 (4.8) は計算する必要がない.

2.Viterbi アルゴリズム

$\lambda=(A,B,\pi)$ が既知の場合に、与えられた観測系列 $O=O_1O_2\cdots O_T$ から、最尤推定になる状態系列 $Q=q_1q_2\cdots q_T$ を動的計画法で求めるアルゴリズムである。動的計画法とは、直接計算すると膨大な時間を要する問題に対し、途中の計算結果を保持し再利用することで計算効率を上げる手法のことである。このアルゴリズムから得られる結果は、最尤推定した状態系列 $q_1^*, q_2^*, \dots, q_T^*$ である。時刻 t までの観測系列と $q_t = S_i$ を出力する、最も確率の高い経路は

$$\delta_t(i) = \max_{q_1, q_2, \dots, q_{t-1}} P[q_1, q_2, \dots, q_{t-1} = S_i, O_1O_2\cdots O_t | \lambda] \quad (4.11)$$

時刻 t で $\delta_t(i)$ を最大化するような状態 $\psi_t(i)$ を計算する。これらの初期値は

$$\delta_1(i) = \pi_i b_i(O_1) \quad (4.12)$$

$$\psi_1(i) = 0 \quad (4.13)$$

となる。再帰式は以下のようになる。

$$\delta_t(j) = \max_{1 \leq i \leq N} [\delta_{t-1}(i) a_{i,j}] b_j(O_t) \quad (4.14)$$

$$\psi_t(j) = \operatorname{argmax}_{1 \leq i \leq N} [\delta_{t-1}(i) a_{i,j}] \quad (4.15)$$

時刻 T まで計算する。最尤状態系列の生成確率を P^* 、最尤状態系列の最終状態を q_T^* とすると

$$P^* = \max_{1 \leq i \leq N} [\delta_T(i)] \quad (4.16)$$

$$q_T^* = \operatorname{argmax}_{1 \leq i \leq N} [\delta_T(i)] \quad (4.17)$$

となる。最終状態がこれで決定した。ここまでで最も確率の経路を導出することができるが無駄が多い。Viterbi アルゴリズムの途中の計算結果を保持し再利用することが考慮されて

いないのでバックトラックを計算することで最状態系列を求める。バックトラックは探索の際に候補の数をできるだけ少なくおさえて効率よく探索するのが最大の特徴です。

$$q_T^* = \psi_t(q_{t+1}) \quad (4.18)$$

を計算することで最尤状態系列を求められる。

3. クローラー機構から四輪機構への変換

まず，車両では前輪と後輪に垂直な線を引く．線が交わる点を中心として車両の外側前輪の中心までを最小半径とした円が書かれる Fig.4.1. これが大雑把な車両の旋回の仕組みである．次に，MieC の旋回の仕組みは左右のクローラーの速度差により旋回する．なので，内




Fig. 4.1 Turning method of the car

側のクローラーの速度と外側のクローラーの速度が内側の半径と外側の半径の比となる．これが車両にない動きの信地旋回と超信地旋回を可能にする (Fig.4.2). 信地旋回とは，片方のクローラー速度を0にしてもう片方のクローラーに速度指令を出し旋回する方法である．超信地旋回とは，左右のクローラーに別々の向きの速度指令を出し旋回する方法である．この




Fig. 4.2 Long-term relationship and Pivot turn

ような差異をなくすためには，車両と MieC のハンドル切れ角 φ と旋回半径 R の関係式を統一していく必要がある．車両のハンドルとタイヤの切れ角について説明する． Fig.4.3 を使い説明する．ハンドルを切るとハンドル軸が旋回する．そして旋回量だけタイロッドエンド: t が動きタイヤを押すことによりタイヤに切れ角: θ が生じる．このことを数式で表すと




Fig. 4.3 The relation between steering wheel and tire of cutting angle

以下のようになる.

$$r \times \varphi \quad (4.19)$$

ここで, タイヤの切れ角: θ とハンドルの切れ角: φ は次のようになる

$$\varphi = \sin\theta \times t/r \quad (4.20)$$

$t/r=k$ とすると

$$\varphi = \sin\theta \times k \quad (4.21)$$

ここまでで, タイヤの切れ角: θ とハンドルの切れ角: φ の関係を導出した. L をホイールベース距離とする. タイヤの切れ角: θ と旋回半径: R の関係式が成り立つ.

$$\sin\theta = L/R \quad (4.22)$$

式 (4.21), 式 (4.22) より旋回半径とハンドル切れ角の関係式は以下のようになる.

$$\varphi/k = L/R \quad (4.23)$$

式 (4.23) に実際の車両の値を代入して定数: k を求める. 実際の車両の値は最小旋回半径: $R_{min}=4400[\text{mm}]$, トレッド長さ: $W=1645[\text{mm}]$, ホイールベース: $L=2430[\text{mm}]$ の日産マーチ AK12 の値を用いる. そして, ハンドル切り角を 900° とすると定数 $k=0.001227$ と算出で

きた。また、最小旋回半径: R_{min} からそのときのタイヤの切れ角: $\theta=33.5$ と算出できた。また、MieCの値はトレッド長さ $W=130$ [mm], ホイールベース $L=150$ [mm] である。MieCを四輪モデルと仮定する。MieCの最小旋回半径: $R_{min}=271$ [mm] となる。ハンドル切れ角が時計回りを正とし、クローラーの速度: L_v, R_v について Fig.4.4 で定義した。クローラーの速




Fig. 4.4 Definition of the speed direction

度比: L_v, R_v を算出すると以下ようになる。 $\varphi > 0$

$$L_v = 15/30 - 13k\varphi \quad (4.24)$$

$$R_v = 1 - L_v \quad (4.25)$$

$\varphi < 0$

$$L_v = 1 - R_v \quad (4.26)$$

$$R_v = 15/30 + 13k\varphi \quad (4.27)$$

となる。

4.G27のトルク計測



Fig. 4.5 Environment of experiment for measuring torque

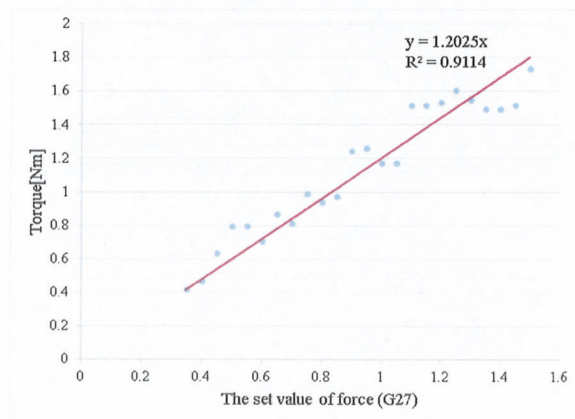


Fig. 4.6 The relationship between set value of force and torque

Fig.4.5 は、設定値をトルクの関係を計測するための実験環境である。計測方法は、ハンドルにバネばかりを吊るして、計測していた。バネばかりを手で押さえ力覚とつり合う値を計測した。同じ設定値に対して3回計測してその平均値を使用した。Fig.4.6 は、力覚とトルク $[N \cdot m]$ の関係を示したグラフである。0.3 $[N \cdot m]$ 以下についてはデータを計測できなかった。これはハンドルにバネばかりを吊るして、計測していたがハンドルが0.3の大きさでは、自重とバネばかりの重さから計測できなかった。力の釣り合いが自重とバネばかりの重さの方が0.3 $[N \cdot m]$ より大きいためである。グラフを見ると線形の関係である。これはR-2乗値が0.9を越えて1に近い数字であることから妥当な補間結果である。実験で使用するトルクは0から0.8 $[N \cdot m]$ とした。これは経験則的に決めたものである。

参考文献

- [1] 報道発表資料 | 警察庁 Web サイト
<https://www.npa.go.jp/news/release/2018/20180103001nemntyuu.html>
- [2] ASV (先進安全自動車) | 自動車総合安全情報 - 国土交通省
<http://www.mlit.go.jp/jidosha/anken/01asv/japanese/practical.html>
- [3] Ryunosuke Hamada, Takatomi Kubo and Kazushi Ikeda et al. “Modeling and Prediction of Driving Behaviors Using a Nonparametric Bayesian Method With AR Models”
IEEE Transactions on Intelligent Vehicles 30 June 2016
- [4] 橋本 幸二郎 道木 加絵 道木 慎二 大熊 繁, “時系列情報を用いた行動モデルに基づく人間の次行動支援”, ロボティクス・メカトロニクス講演会講演概要集, 2010, “2A1-D17(1)”-“2A1-D17(4)”, 2010
- [5] Mohamed Maher Atia, Allaa R. Hilal and Clive Stelling et al. “A Low-Cost Lane-Determination System Using GNSS/IMU Fusion and HMM-Based Multistage Map Matching” IEEE Transactions on Intelligent Transportation Systems 14 March 2017
- [6] Ziya Ercan, Ashwin Carvalho, Metin Gokasan and Francesco Borrelli “Modeling, Identification, and Predictive Control of a Driver Steering Assistance System” IEEE Transactions on Human-Machine Systems 12 September 2017
- [7] 高橋 樹生 中野 公彦 鄭 仁成 大堀 真敬 瀬川 雅也 石原 敦, “力覚指示と軌道誘導による車線変更支援”, 生産研究 67(2), 195-198, 2015

- [8] Penglei Dai and Jay Katupitiya “Force control of a 4WS4WD vehicle for path tracking”
Advanced Intelligent Mechatronics (AIM), 2015 IEEE International Conference on
korea
- [9] 廣川 暢一 上杉 直久 古郡 了 北川 朋子 鈴木 健嗣, ” 駐車運転技量育成のための力
覚呈示を用いた運転行動支援システム ” , 計測自動制御学会論文集 = Transactions of the
Society of Instrument and Control Engineers 49(6), 602-611, 2013-06-30
- [10] 神村 吏 木谷 友哉, ” SVM を用いた二輪車の運転挙動分類の基礎検討 ” , マルチメディア、
分散協調とモバイルシンポジウム 2014 論文集, 44-52, 2014-07-02
- [11] 渋谷 奈保 高橋 友和 井手 一郎 村瀬 洋 小島 祥子 高橋 新, ” 距離データ系列の
照合による自車位置推定と走行車線認識 ” , 情報処理学会研究報告コンピュータビジョン
とイメージメディア (CVIM), 17-22, 2007-09-03
- [12] Jrme Maye, Rudolph Triebel and Luciano Spinello et al. “Bayesian on-line learning of
driving behaviors” Proceedings of the Robotics and Automation (ICRA), 2011 IEEE
International Conference on china
- [13] Yang Zheng and John H. L. Hansen “ Lane-Change Detection From Steering Signal
Using Spectral Segmentation and Learning-Based Classification ” IEEE Transactions
on Intelligent Vehicles 25 May 2017
- [14] Mingming Zhang, Chao Chen and Tianyu Wo et.al “ SafeDrive: Online Driving
Anomaly Detection From Large-Scale Vehicle Data ” IEEE Transactions on Industrial
Informatics 24 February 2017
- [15] Wenshuo Wang, Junqiang Xi and Alexandre Chong et.al “Driving Style Classification
Using a Semi supervised Support Vector Machine ” IEEE Transactions on Human-
Machine Systems 23 August 2017

- [16] 西脇 由博 宮島 千代美 北岡 教英 武田 一哉, "確率的手法を用いた車線変更軌跡のモデル化", 情報処理学会論文誌 Vol.51 No.1 131-140 (Jan. 2010)
- [17] 玉井克幸ら "人の意思と機械の判断を融合する操作支援システム", 三重大学大学院修士学位論文, 2012
- [18] 益川勇貴ら "人と自動四輪車の力覚コミュニケーションによる運転操作システム", 三重大学卒業論文, 2016

謝辞

本研究を遂行および修士論文の作成に当たり、御指導と御鞭撻を賜りました三重大学 松井 博和 助教に対して、深く感謝いたします。

文の構成論理展開などを英語で指導して下さったマレーシア Universiti Malaysia Perlis の Abdul Hamid Adom 先生に対して深く感謝します。

I appreciate prof. Abdul Hamid Adom for supervising me sentence structure and theoretical development.

また、本研究を進めるにあたり、実験に協力して頂いた河合君、中井さん、中島さん、岡村君、小谷君、高村君、松崎君、東君、加藤君、倉本君、清水君、田畑君、宮脇君に心より感謝いたします。

本研究に際して、様々なご指導を頂きました三重大学 加藤典彦 准教授さらに矢野賢一 教授、に対して感謝いたします。