

時間整合アルゴリズムに基づくタイヤ振動解析法
—リアルタイム路面状態判別システムの開発—

花塚泰史

博士（学術）

総合研究大学院大学

複合科学研究科 統計科学専攻

平成 24 年度

目次

第 1 章	はじめに	1
1.1	研究の背景	1
1.2	本論文の構成	3
第 2 章	先行研究の概説と本研究の目的	4
2.1	先行研究のシステム構成	4
2.2	先行研究で採用したタイヤ振動波形の特徴定量化法	5
2.3	先行研究で開発した判別アルゴリズム	6
2.4	先行研究の実験結果	7
2.5	先行研究の問題点と本研究の目的	7
第 3 章	タイヤ振動波形の特徴	9
3.1	タイヤの動的挙動と振動波形の対比	9
3.2	路面状態変化によるタイヤ振動波形の変化	13
3.3	タイヤ振動波形の特徴定量化法	30
第 4 章	隠れマルコフモデルによるタイヤ振動のモデル化と路面状態判別方法	33
4.1	隠れマルコフモデル	33
4.1.1	マルコフモデル	33
4.1.2	隠れマルコフモデルの定式化	34
4.1.3	EM アルゴリズム	36
4.2	HMM によるタイヤ振動のモデル化と判別方法	40
4.3	実験	44
4.3.1	実験方法	44
4.3.2	HMM による状態推定	47
4.3.3	HMM に基づく判別手法の精度	49

4.3.4	サイズロバスト性の検証	57
4.3.5	出力確率関数として用いた GMM の混合数の影響	67
4.4	この章の考察とまとめ	76
第 5 章	カーネル法を用いたタイヤ振動のモデル化と路面状態判別方法	78
5.1	カーネル法	78
5.1.1	サポートベクターマシン	78
5.1.2	GA カーネル	88
5.2	カーネル法を用いた判別方法	90
5.3	実験	93
5.3.1	GA カーネルを用いた手法の精度	94
5.3.2	サイズロバスト性の検証	100
5.4	この章の考察とまとめ	116
第 6 章	結論	119
付録	交差確認法によるカーネル法のパラメータ設定	121

第 1 章 はじめに

1.1 研究の背景

平成 23 年（2011 年）版 警察白書によれば，日本国内における 2010 年中の交通事故による死者数は 4,863 人で、10 年連続の減少となるとともに、1952 年以来 57 年ぶりに 4 千人台となった 2009 年を更に下回った。また、交通事故発生件数及び負傷者数も 6 年連続で減少し、負傷者数は 16 年ぶりに 90 万人以下となった [1]。この背景には、法令整備によるシートベルト着用率上昇や悪質運転の減少のほか，エアバッグや衝突安全ボディなど事故発生時に人体への影響を最小限に抑えるパッシブセーフティ技術，ABS（Anti lock Brake System，車輪固着防止装置）や ESC（Electronic Stability Control，横滑り防止装置）など事故を未然に防ぐアクティブセーフティ技術という車両安全技術の向上がある。またさらに安全な交通社会を実現するため，2011 年に内閣府が策定した第 9 次交通安全基本計画では，2015 年までに交通事故による死者数を 3,000 人以下にするという目標が掲げられている。この達成のためには車両の安全性の確保が必要であると明記されており [2]，特にアクティブセーフティ技術の更なる発展と普及は不可欠である。

アクティブセーフティ技術はこれまで，国土交通省と各車両メーカーが参画する先進安全自動車（ASV）推進検討会によって技術の開発・実用化・普及が検討され，多くの技術が各車両メーカーの製品に搭載されてきた [3]。アクティブセーフティ技術に代表される車両制御技術の高度化，複雑化は，車両の動的な挙動や周辺環境をセンシングするセンサ，カーナビや ECU（Electronic Control Unit，電子制御装置）などの情報処理装置，車両と外部との通信装置など数多くの車載電子デバイスによって実現されている。車輪速センサや加速度センサ，ヨーレートセンサ等の情報を用いて車両の挙動や路面の滑りやすさなどを推定し，制御にフィードバックしているが [4] [5] [6] [7]，数万点に及ぶ自動車部品で唯一路面と接しているタイヤにセンシング機能を付加できれば，車両の挙動や路面状態などがより正確に把握できると考えられる。近年の計測技術の向上によって，タイヤに直接電子デバイスを装着し，高速で回転するタイヤから物理量を計測して車両に転送することが可能になってきた。タイヤの空気圧と温度を計測し，その情報を車両へ無線送信する TPMS（Tire Pressure Monitoring System，タイヤ空気圧監視システム）はすでに実用化され，アメリカやヨーロッパでは新車への装着が義務付けられている [8] [9]。また加速度や歪といったより動的な物理量を取得する技術の

研究がタイヤメーカ各社や各研究機関において行われており，このようなセンシング機能を持つタイヤ技術はインテリジェントタイヤと呼ばれている [10] [11]. [12]はタイヤの側面部の変形を直接的に計測してタイヤにかかる力を推定する，最も初期のインテリジェントタイヤ技術である． [13]はタイヤインナーライナー面に MEMS(Micro Electro Mechanical Systems)式 3 軸加速度センサを貼付け，その出力波形からタイヤにかかる力，空気圧，路面の凹凸，水膜の有無を推定するシステムを提案している．

このようなタイヤにかかる力を推定する技術のほかに，路面の状態（滑りやすさ）を推定する技術が提案されている．路面状態や路面の滑りやすさはタイヤと車両の安全性を確保するために重要な情報であり，上述のようにこれまでは間接的にしか推定できなかったが，より直接的に精度良く推定することが求められている．

APOLLO-project(活動期間 2002 年から 2005 年)は EC(European Commission：欧州委員会)のサポートを受けて，主にヨーロッパの自動車メーカや電装メーカ，タイヤメーカ，大学等研究機関が参加した，インテリジェントタイヤの開発及び利活用を研究するプロジェクトである．このプロジェクトの最終報告書 [10]において，光学センサを用いたインテリジェントタイヤが提案されている．この光学センサタイプのインテリジェントタイヤは，タイヤインナーライナー部に LED(Light Emitting Diode)を取り付け，その光源の変位をホイール気室側に取り付けたフォトダイオードの表面抵抗を利用した 2 次元位置検出器で検出し，タイヤインナーライナー面の変位に変換することで，タイヤにかかる 3 方向の力を推定する．推定した路面と水平方向の力に対する垂直方向の力の比からタイヤと路面間の摩擦係数を算出するシステムである [14].

[15]では，SAW(Surface Acoustic Wave：弾性表面波)センサがトレッドブロックの動きを測定するように構成されている．すなわちピンがタイヤインナーライナー面からベルト部に向かって挿入されており，ピンの曲げ変形を SAW センサが検出する構造になっている．これによりトレッドブロックの変形を評価し，路面摩擦係数を推定する．

筆者らはこれまで、タイヤ内面に加速度センサを取り付け，その出力が路面状態によって変化することを見出し、その逆問題としてタイヤ振動の特徴から定常走行中リアルタイムに路面状態を判別する技術の開発を行ってきた [16] [17]

[18]. 開発したシステムは実用性のある精度で判別できる一方、多様なセンサを必要とし複雑化しているなどの課題があった. 本研究はタイヤ内面にとりつけた加速度センサの波形の特徴から路面状態を判別するというコンセプトは踏襲し、より一般の自動車にも搭載できるような簡素なシステムで実現するためのアルゴリズムの開発を目的とする.

一方、統計的機械学習は経験や実験から得た情報の中から、後に再利用できそうな情報を獲得する過程を自動的に行う技術である. 例えば、センサなどの出力から、入力されたシステムの状態を推定する逆問題の 1 つの解法として、統計学や応用数学の分野のみならず工学や産業界からも注目されている. 本研究ではこのような機械学習やパターン認識等の統計的手法の枠組みを、インテリジェントタイヤ開発に応用することによって、より簡素なシステムで先行研究 [16] [17] [18]と同等以上の精度と各種外乱に対するロバスト性を有する技術の開発を目指す.

1.2 本論文の構成

第 2 章で、上述の先行研究 [16] [17] [18]について概説する. その問題点を整理し、本研究の目的を明確にする. 第 3 章で、本論文で提案するアルゴリズムを適用する対象であるタイヤ振動の特徴をタイヤの動的挙動と対応させて述べる. 第 4 章ではタイヤ振動のモデル化に使用した HMM (Hidden Markov Model, 隠れマルコフモデル) に関し、状態空間モデルにおいて潜在変数を持つ確率モデルの解釈と、モデルのネットワーク構成、更にはモデルのパラメータを推定するためのアルゴリズムについて説明するとともに、タイヤ振動を各路面状態毎にモデル化して判別する方法について述べる. 第 5 章では、SVM (Support Vector Machine, サポートベクターマシン) に関して解のスパース性やモデルパラメータが凸最適化問題の解として求まることについて説明する. また SVM がカーネル法によって非線形化できるという一般的な解釈に加え、特に本論文で重要な要素となる時間伸縮に対応するカーネルである、DTW (Dynamic Time Warping, 動的時間伸縮) カーネルおよび GA (Global Alignment, 大域的アライメント) カーネルの特徴について説明し、路面状態判別への応用方法と実験結果について述べる. 最後に第 6 章で各手法の比較など考察を行う.

第 2 章 先行研究の概説と本研究の目的

本章では筆者らが別に行った先行研究 [16] [17] [18]について概説するとともに，その問題点を整理し，本研究の目的を明確にする．

2.1 先行研究のシステム構成

本節では先行研究 [16] [17] [18]で開発されたシステムについて説明する．図 1 にシステムの構成図を示す．

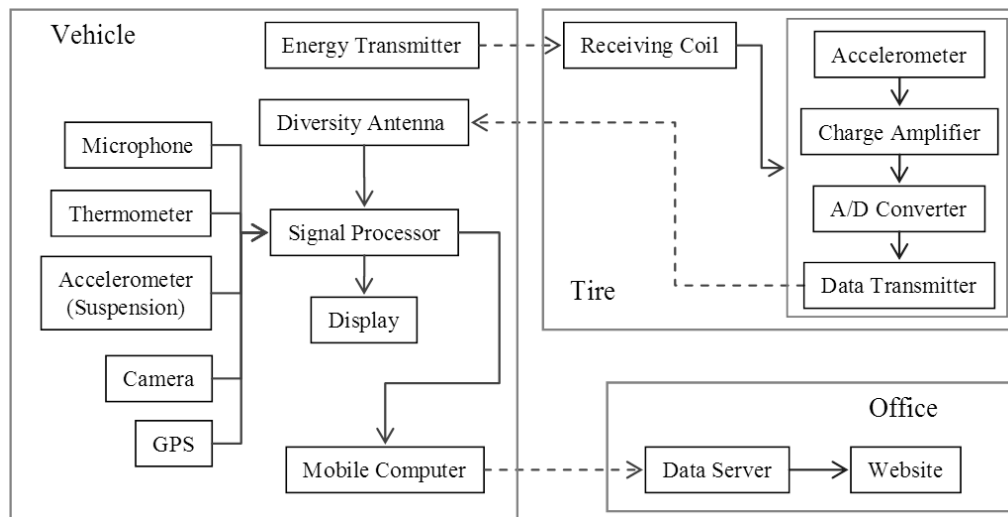


図 1 先行研究システムの構成図



(a)給電アンテナ



(b)受電コイル

図 2 ワイヤレス給電システム

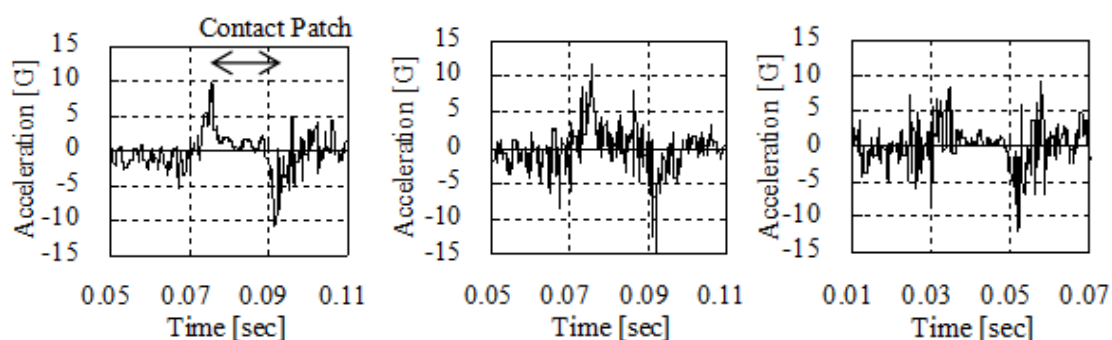
回転体であるタイヤ内のセンサを駆動する為に，電磁誘導を利用してワイヤレス給電を行うバッテリーレス計測システム（図 2）を開発し用いている．図 2(a)に示す給電アンテナ（1 次コイル）は左前輪サスペンション部に固定し，タイヤ

との間隔を一定に保つようにしている．タイヤのトレッド内面部には，図 2(b)に示す受電コイル（2 次コイル）の連結体を装着している．送電電力は約 100mW で，各環境下で最適な送電効率を得るために交流電流の周波数を制御している．加速度センサは 1 軸電荷出力タイプで，周上 1 箇所に装着され，送電された電力により駆動される．チャージアンプで増幅された信号は，無線データ送信装置によってホイールハウスのダイバーシティアンテナへ連続的に送信され，更に車内の解析装置へと送られる．なお，データ分解能は 24bit，サンプリングレートは 20kHz である．

このシステムはタイヤ加速度の他に，タイヤ発生音を計測するマイクロフォン，路面温度を計測する赤外温度計，タイヤへの大きな入力を検出するサスペンション部の加速度センサを備える．マイクロフォンはタイヤ加速度に特徴が現れないような薄く濡れている程度のウェット路面を検出する．赤外温度計は経験的に湿潤状態が存在し得ない状況を判定している．悪路，特に段差乗り越しなどの状況において誤判定が多くなるので，サスペンション部の加速度センサが大きな入力を検出した場合に判定を中断するようにしている．なお，タイヤは 265/65R17 サイズのスタッドレスタイヤである．

2.2 先行研究で採用したタイヤ振動波形の特徴定量化法

上述のシステムで取得したタイヤ振動波形は，路面状態毎に異なった特徴を持つ．図 3 に各路面状態を走行中に取得したタイヤ振動波形の例を示す．



(a)ドライアスファルト

(b)凍結路

(c)ウェットアスファルト

図 3 タイヤ振動波形の例

平滑な乾燥アスファルト路面において，時速 20km/h で収集した周方向加速度波

形の例を図 3(a)に示す. 2 つのピークは接地面端部で, ピーク間が接地面である. 乾燥路では路面からの拘束力が強いために, 接地面内のトレッドの動きが少なく, 振動レベルが低いことが特徴である. 一方, 図 3(b)に示す氷路では, 定常走行中でもミクロな滑りが頻繁に起こるため, 接地面内で高周波振動が発生する傾向にある. そして, 滑りによりトレッドゴムのせん断力が接地面内で解放されるために, 接地面後方 (蹴出し端以降) の振動レベルが低いという特徴を有する. また, 図 3(c)に示す水深約 2mm の湿潤アスファルト路面では, トレッドブロックと水膜の衝突により, 接地前方 (踏込み端前) の振動レベルが高くなっている.

先行研究 [16] [17] [18]では上記各路面走行時のタイヤ振動の特徴を定量化する為, まず時系列波形を複数の時間領域に分割する. 時間領域は車輪速によって変化するので, 正確な窓掛けをするため, 車輪速を別途計測しウィンドウ幅を調整する必要がある. その後, 分割した時系列ごとにデジタルフィルタを用いて各領域の特定周波数帯域の振動レベルを求めて特徴量としている. 具体的な時間領域の位置や長さ, 周波数帯については明らかにされていない.

2.3 先行研究で開発した判別アルゴリズム

2.2 で説明した特徴量を基に, 2 値判別器を複数組み合わせ, まず図 4 に示すように乾燥/深い湿潤/湿潤/低 μ 路の 4 段階に判別する. その後「低 μ 路」をさらにシャーベット/積雪/圧雪/凍結に判別し, 最終的に乾燥/湿潤/シャーベット/積雪/圧雪/凍結の 6 区分に状態を判別している. 2 値判別器について具体的な手法については述べられていない.

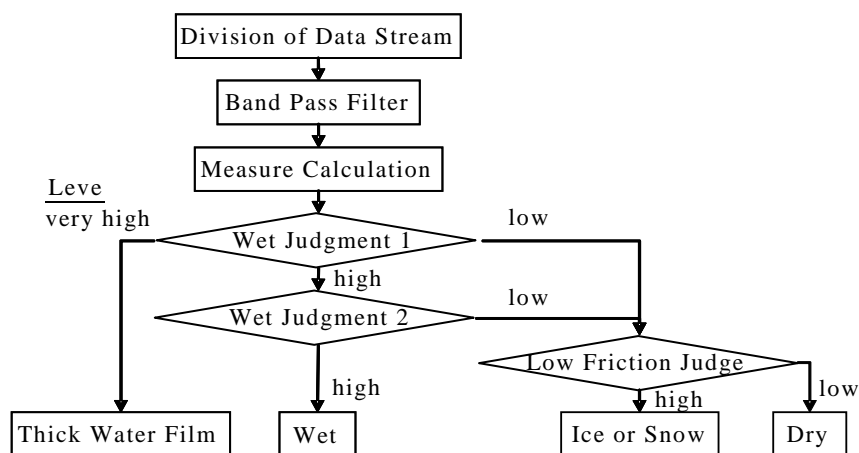


図 4 判定フロー図

2.4 先行研究の実験結果

このシステムの精度を検証するため、冬季 2 シーズン（第 1 季：2008/12-2009/3，第 2 季：2009/12-2010/3）公道で試験を実施している。市街地，郊外幹線道路，山間部を含む 100km 程度の 2 つのコースを設定し，週に 3～5 日走行し精度を求めた。実験車両には運転者以外に目視判定員が同乗し，500m 程度のチェック区間毎の目視判定結果，目視に対するシステム判定結果の正誤状況等を，○（正答），×（誤答），△（正答と誤答がほぼ半数ずつ）の 3 段階で逐次判定した。正答（○）を 1、正誤混在（△）を 0.5 とカウントして判定総数で除したものを正答率とし，各路面毎，シーズン毎に比較した結果を図 5 に示す。第 1 季は特にシャーベットと圧雪の精度が低かったが，第 2 季ではそれぞれ精度は大きく向上した。シーズン通しての平均正答率は第 1 季の 74%から第 2 季は 82%に向上し，[17] [18]では実用性が大きく向上したと評している。

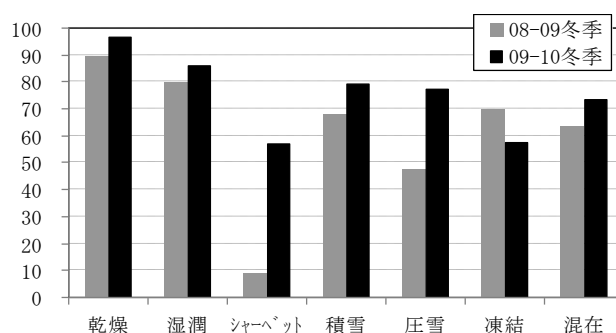


図 5 先行研究の正答率

2.5 先行研究の問題点と本研究の目的

上述のように，先行研究 [16] [17] [18]はタイヤ振動の特徴を捉え，実用可能性のある精度で路面状態を判別できるシステムを提案した。しかし，一般の自動車への装着を想定したとき，以下のような問題点がある。

1. 車輪速やマイクなど複数のセンサや情報が必要であり，システムの複雑化，開発コストの増大を招いている

2. 1つのサイズ, 1つのトレッドパターン (溝のデザイン) にしか対応できない

これは先行研究 [16] [17] [18]が冬季道路管理という特殊な用途への適用を想定しており, 判別する路面状態が多様であり, また精度が最も重要視されていることに起因するものである.

そこで, 本研究では一般の車両へも装着できる路面状態判別システムの開発を目的とし, 車輪速など車両側の情報を必要とせず, タイヤ振動情報のみで定常走行中リアルタイムに路面状態を判別する方法を提案する. また, タイヤは車種やユーザーの趣向に合わせて多様なサイズが存在するので, タイヤサイズロバスト性についても議論する. 最も開発コストがかかるデータの取得と学習に費やす工数を大幅に削減するため, 一つのタイヤサイズのデータで学習すれば, 異なる複数のタイヤサイズのデータにも対応できるシステムを目指す.

次章ではまず, 本研究で扱うタイヤ振動の特徴を説明し, 上述のような先行研究の問題を解決し目的を達成するために解くべき技術課題を明確にする.

第 3 章 タイヤ振動波形の特徴

本章では，本研究で扱うタイヤ振動がどのような要因に影響を受けて変化するかを，タイヤの動的挙動や路面状態の変化と結び付けて説明する．その上で本研究が解くべき技術課題を明確にするとともに，波形の特徴を定量化する手法について説明する．

3.1 タイヤの動的挙動と振動波形の対比

本節では走行中のタイヤ振動波形の特徴を，タイヤと路面間の相互作用によるタイヤの動的挙動と対応づけて説明する．

タイヤは有機繊維やスチールコードをゴムで挟んだ積層構造になっており，圧縮空気を充填したタイヤを路面に接地させ荷重をかけると，これらの構造物の剛性と空気圧によって決まるバネ特性に基づきタイヤは変形する [19]．タイヤが回転すると，その変形はタイヤの周上の位置を連続的に移動するため，タイヤ内面の任意の一点に圧電式加速度センサを取り付け計測すると，その波形は上述のようなタイヤ回転に伴う動的な接地状態変化を反映した非定常性の強い波形を示す．図 6 は検出軸方向をタイヤの進行方向とした場合の波形の例とタイヤの接地状態の関係を示したものである．巨視的にはタイヤが路面に押しつけられ，ベルト部が屈曲してセンサの軌道が円運動から外れることに起因して，路面踏み込みと蹴り出しに対応する位置において，波形にピークが現れる．走行中のタイヤ振動を計測すると，このようなマクロなタイヤ変形に基づく比較的低周波な振動波形に，タイヤと路面の衝突に起因するロードノイズやパターンノイズ，タイヤと路面間の滑りに起因する振動など比較的高周波な振動が加算された波形が得られる．これらタイヤから発せられる高周波振動は，一部は空気伝搬することによってタイヤ騒音となる．その低減のため，タイヤ振動とタイヤの動的挙動と結び付けて様々な研究がなされてきた [19] [20]．タイヤと路面間の相互作用により，タイヤに入力される振動は以下のように大別できる [20]．1 つは，タイヤのパターン（溝のデザイン）による入力である．トレッドの横溝がタイヤ回転にともない周期的に路面と接触するために，速度に応じて特定の周波数帯の振動がタイヤに入力される．実際のタイヤでは，パターンピッチ（横溝の周方向間隔）を複数種類用意し，振動エネルギーを分散させるようにするが，スペクトルを取ると数百 Hz の帯域にある基本周波数の周りにピークが現れる．2 つ目に路面凹凸による入力

ある．この2つの入力を考慮すると，実際の走行時のタイヤ振動およびタイヤ騒音に近いモデルが構築できる [20]．図 7 はタイヤのパターンピッチによる入力と路面凹凸による入力をモデル化し，タイヤ振動に起因する騒音を予測したものである．路面踏み込み，蹴り出し時にタイヤと路面との衝突にともなうピークが現れるとともに，路面凹凸による細かな成分が加算されている．これに加えてタイヤと路面間の滑りによる入力がある．図 8 に示すように，自由転動中のタイヤはトレッド表面とタイヤ内部のベルト部に相対変位が発生する．それによって接地面蹴り出し側では滑りを伴って路面から離脱する．この滑りは高周波振動を発生させる．また蹴り出し時に上記の相対変位による剪断力が解放されるので，蹴り出し後にトレッドブロックが固有振動することも入力の一つとなる [16] [17] [18]．これらタイヤへの入力は路面状態によって変化することが分かっている [16] [17] [18]．パターンピッチによる入力は，スペクトルの数百 Hz の周波数帯にピークを持つが，路面上に雪や水膜といった，衝撃を緩衝するものがある場合低下する．路面凹凸による入力は 1kHz 以上の周波数帯に現れ，タイヤが相互作用する対象（アスファルト，雪，氷）によって異なる．また滑りやすい路面ではタイヤがマクロなスリップ状態になくても接地面内で微小に滑りが生じ，それによる 1kHz 以上の高周波振動が生じることが分かっている．蹴り出し後に現れるトレッドブロックの固有振動は 1kHz から 2kHz 付近にあり，その大きさは蹴り出し時にトレッドが蓄えている剪断力に依存するので，摩擦係数が低く，蹴り出し前に剪断力が徐々に開放されるような条件では小さくなる．このようなメカニズムで生じるタイヤへの入力に基づくタイヤ振動について，次章では具体的に計測例を示しながら，路面状態変化と結び付けて説明する．

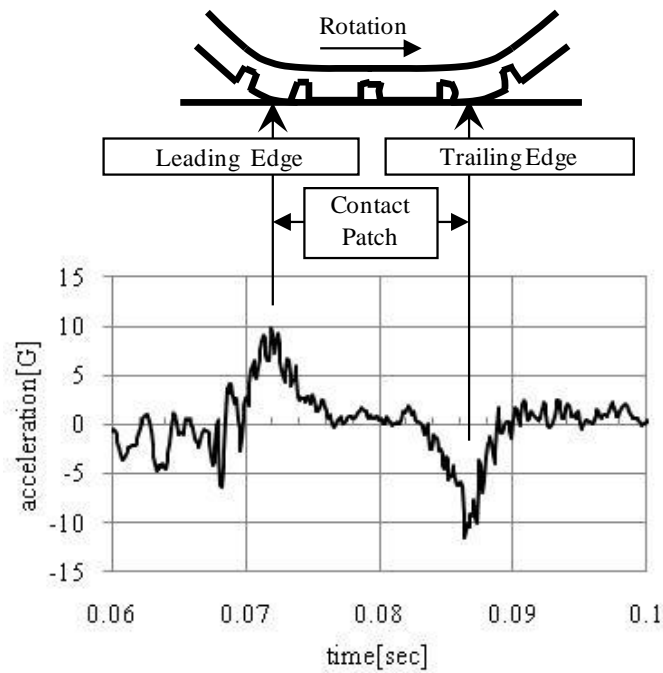


図 6 タイヤ接地挙動とタイヤ振動波形（周方向）の関係

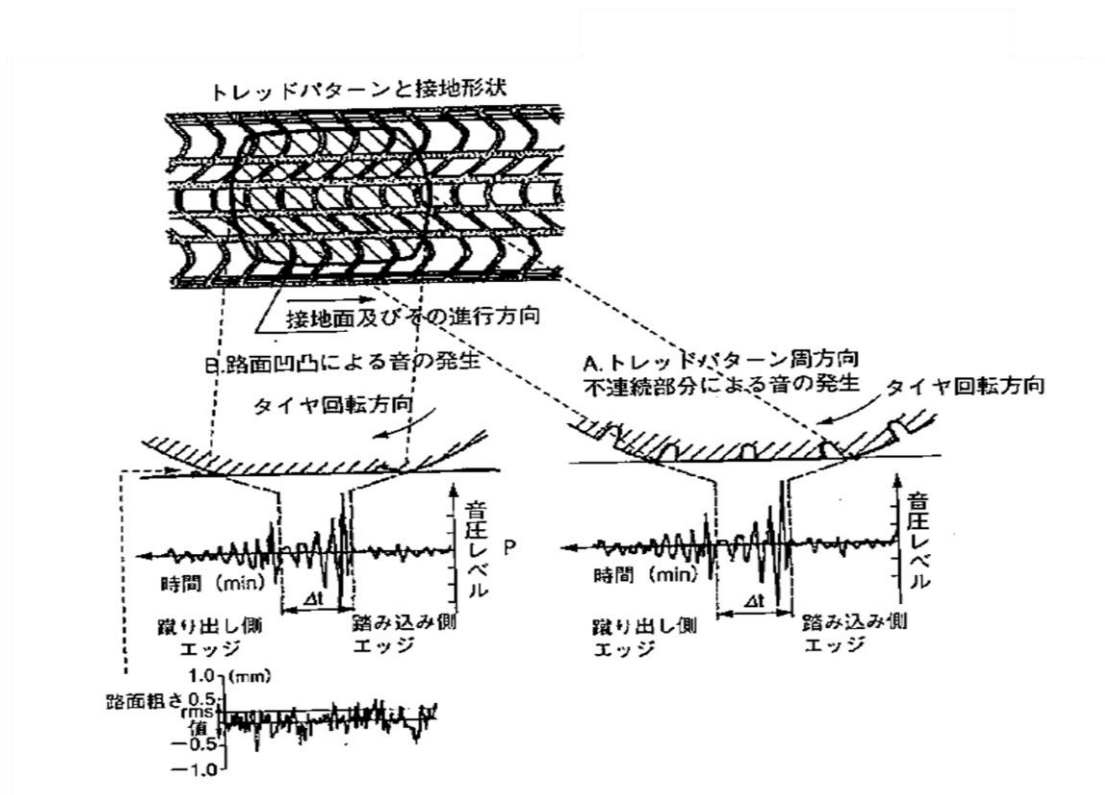


図 7 パターンピッチの入力と路面凹凸の入力を考慮した振動の予測

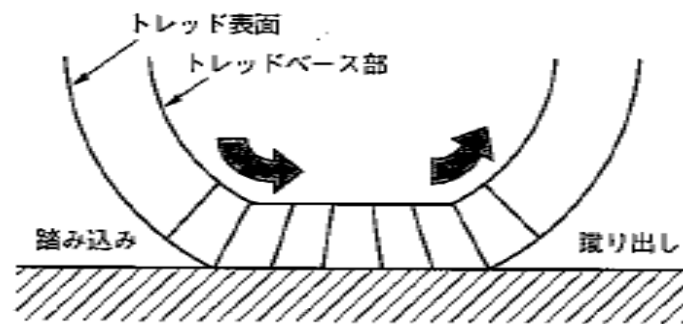
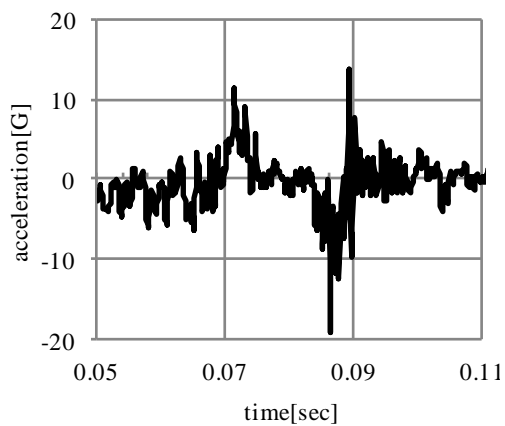


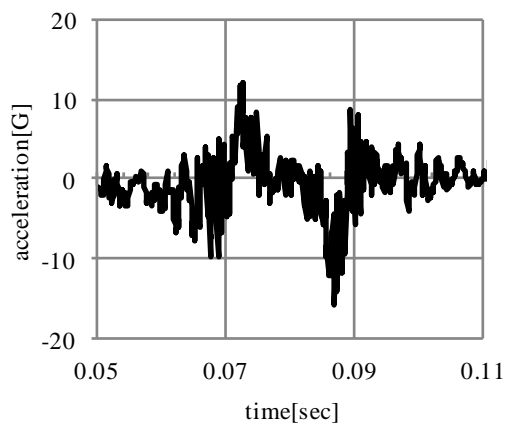
図 8 接地面におけるトレッド部相対変位

3.2 路面状態変化によるタイヤ振動波形の変化

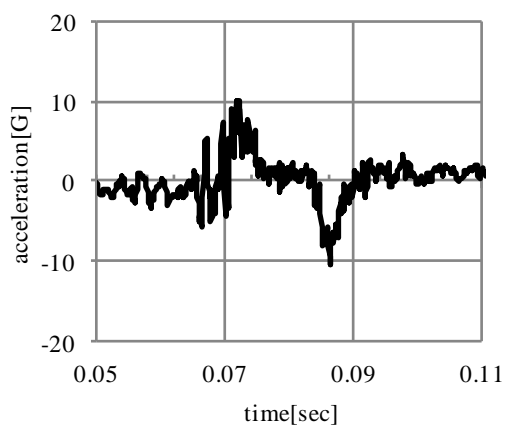
前節では走行中のタイヤ振動波形の特徴を，タイヤと路面間の相互作用によるタイヤの動的挙動と対応づけて説明した．本節ではタイヤの動的挙動が様々な路面状態において変化し，その結果タイヤ振動波形の特徴がどのように変化するかを説明する．図 9 はドライアスファルト，ウェットアスファルト，圧雪路，凍結路をそれぞれ時速 30km で走行した時のタイヤ振動波形である．ウェットアスファルトではタイヤが路面と接触する前に水膜と衝突するため，波形に現れる接地時のピークより前の時間位置の細かな振動がドライアスファルトに比べ，増大していることが分かる．一方，圧雪路や凍結路では，本データを取得した条件において路面性状が平滑であったため，ドライアスファルトに比べ全体的に波形の細かな振動が低下している．加えて，路面摩擦係数の低い圧雪路や凍結路ではタイヤと路面が接地している面（接地面）に働く剪断力が小さいため，路面蹴り出し時の剪断力開放に伴って発生するゴムブロックの固有振動が励起されにくくなっていることが，蹴り出し時に現れるピークよりも後の時間位置における振動レベルが低下させていると考えられる．



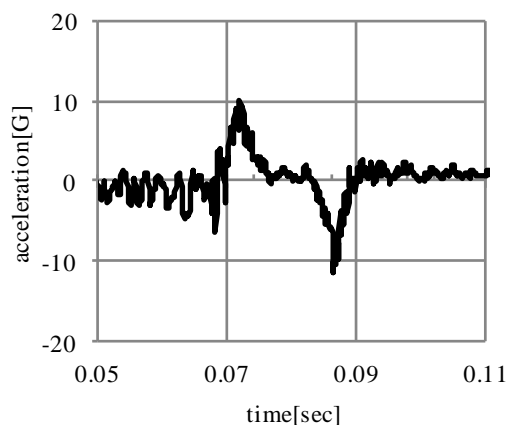
(a) ドライアスファルト



(b) ウェットアスファルト



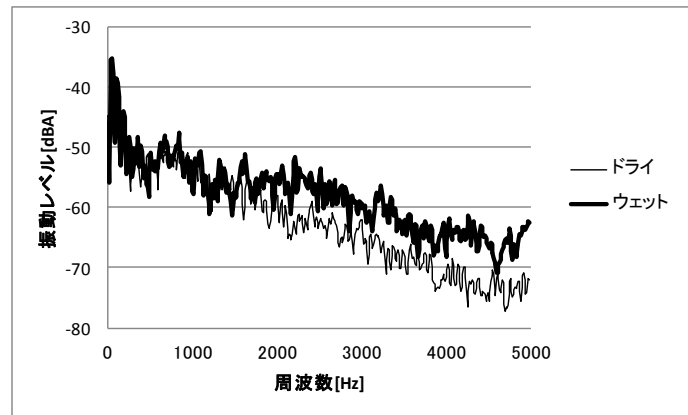
(c) 圧雪路



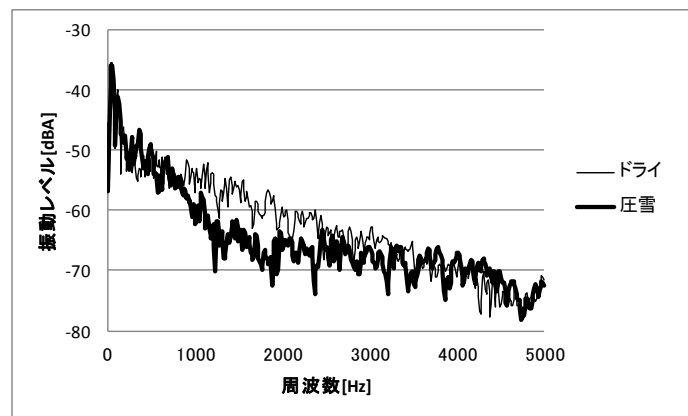
(d) 凍結路

図 9 各路面状態走行時のタイヤ振動波形の例

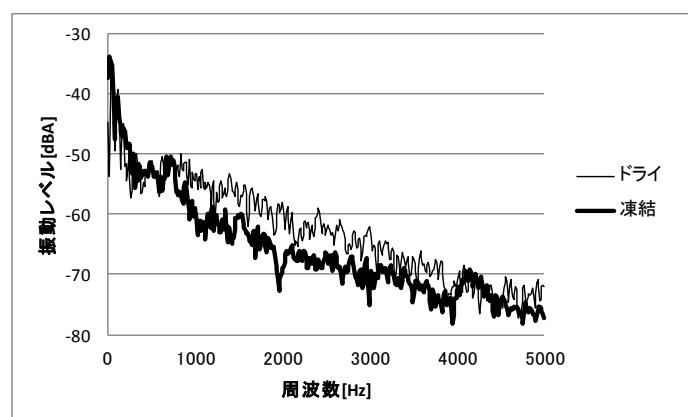
このような波形の特徴を，周波数軸で比較した．図 10 はドライアスファルト，ウェットアスファルト，圧雪路，凍結路をそれぞれ時速 30km で走行中に，サンプリングレート 10kHz で計測したタイヤ振動波形のパワースペクトルである．周波数分解能は 10Hz である．



(a) ドライアスファルトとウェットアスファルトの比較



(b) ドライアスファルトと圧雪路の比較



(c) ドライアスファルトと凍結路の比較

図 10 各路面状態走行時のタイヤ振動の FFT 波形の例

図 10(a)では、2kHz 以上の周波数帯で、上述のタイヤと水膜の衝突によるレベルの上昇がみられる．図 10(b)および図 10(c)では、1kHz 以上の周波数帯で、ドライアスファルトとの差がみられる．これは前述の路面平滑性とブロック固有振動の低下に起因するものと考えられる．このような波形の特徴を、更に詳細に調べるため、時速 30km/h で走行時の振動波形を代表例として、2.1 節で述べたタイヤの接地挙動を考慮して経験的に定めた所定の領域に分割・窓掛けし、それぞれについてのパワースペクトルを調べた．図 11 にウィンドウの位置の例を示す．ウィンドウ位置は路面蹴り出し時に発生するピークを基準として、表 1 に示すように設定した．

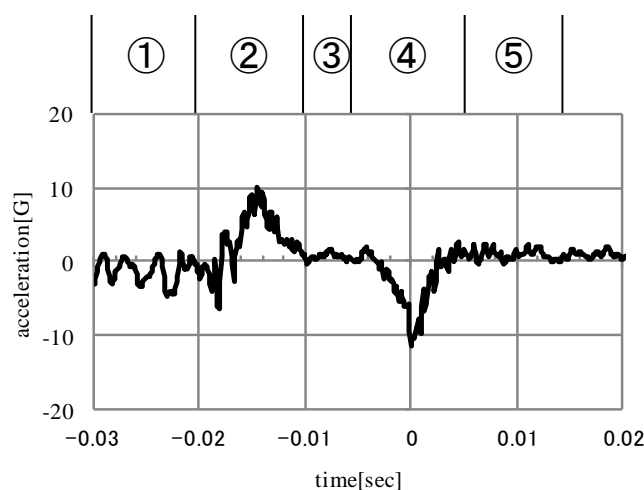
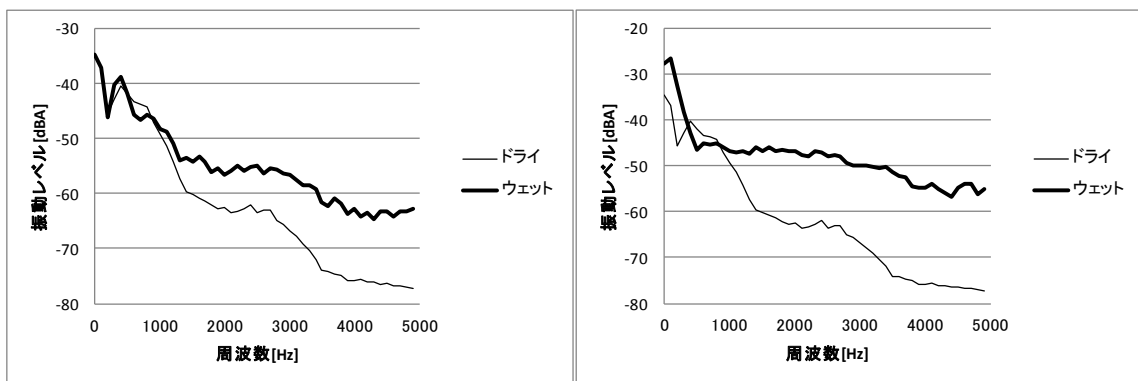


図 11 タイヤ振動波形のウィンドウ位置例

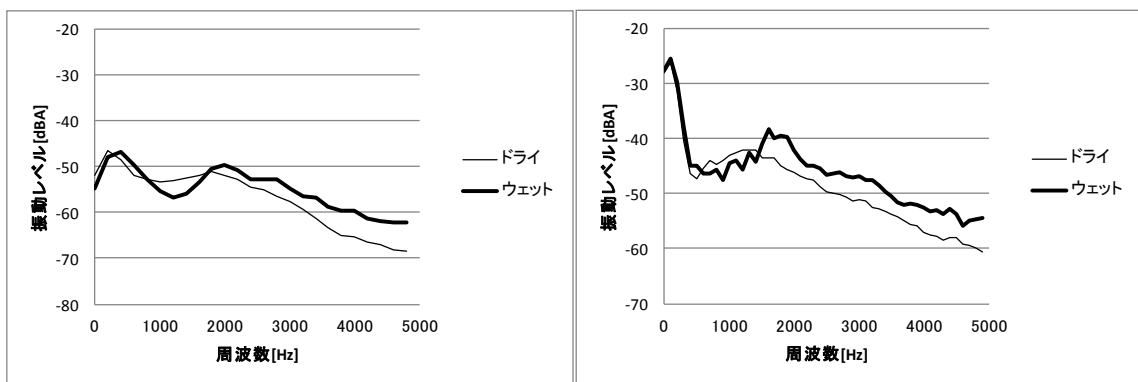
番号	名称	ウィンドウ位置の基準
①	踏み込み前	踏みピーク位置の前方
②	踏み込み	踏みピーク位置を包含
③	接地面	踏みピークと蹴りピーク間
④	蹴り出し	蹴りピーク位置を包含
⑤	蹴り出し後	蹴りピーク位置の後方

表 1 ウィンドウ位置の設定



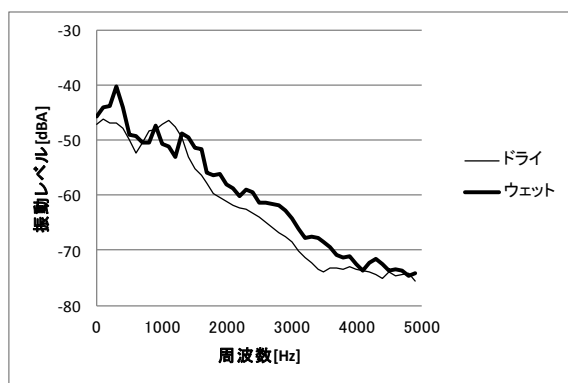
(a) 踏み込み前領域の比較

(b) 踏み込み領域の比較



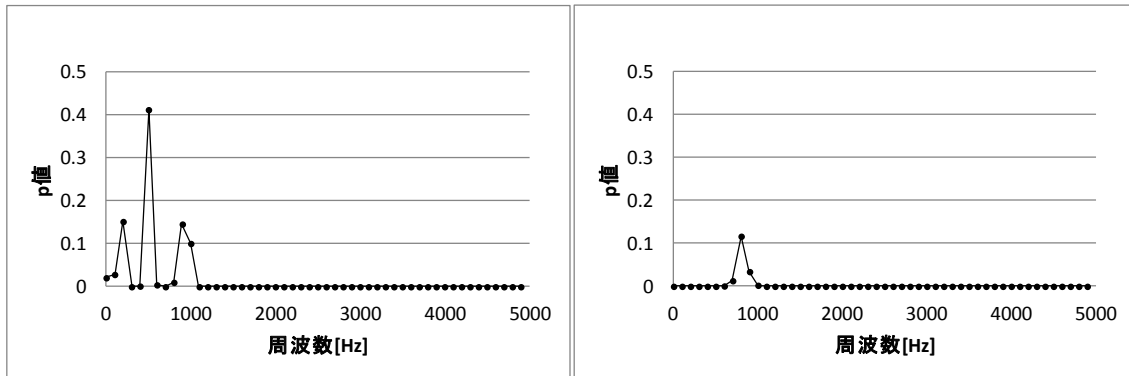
(c) 接地面領域の比較

(d) 蹴り出し領域の比較



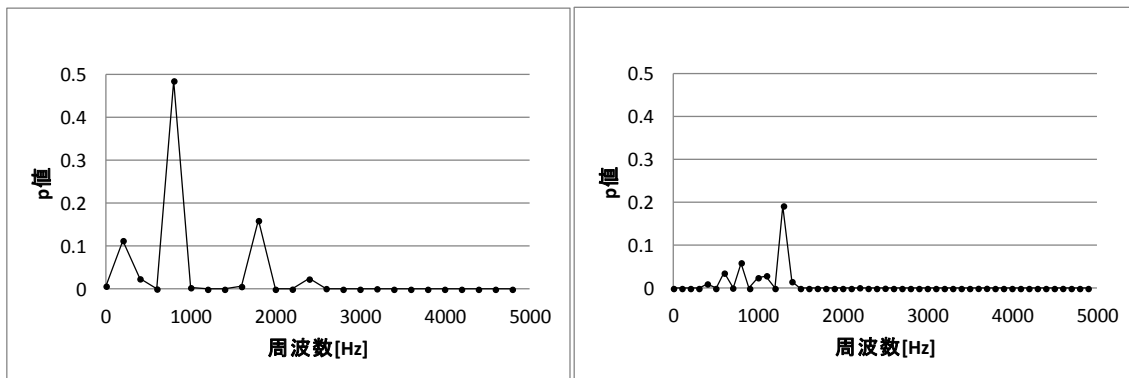
(e) 蹴り出し後領域の比較

図 12 各領域におけるドライとウェットの FFT スペクトル比較



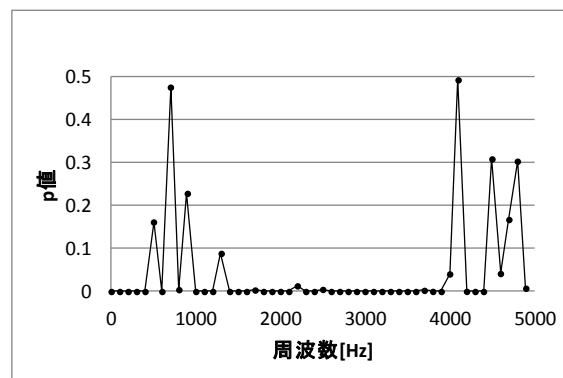
(a) 踏み込み前領域の比較

(b) 踏み込み領域の比較



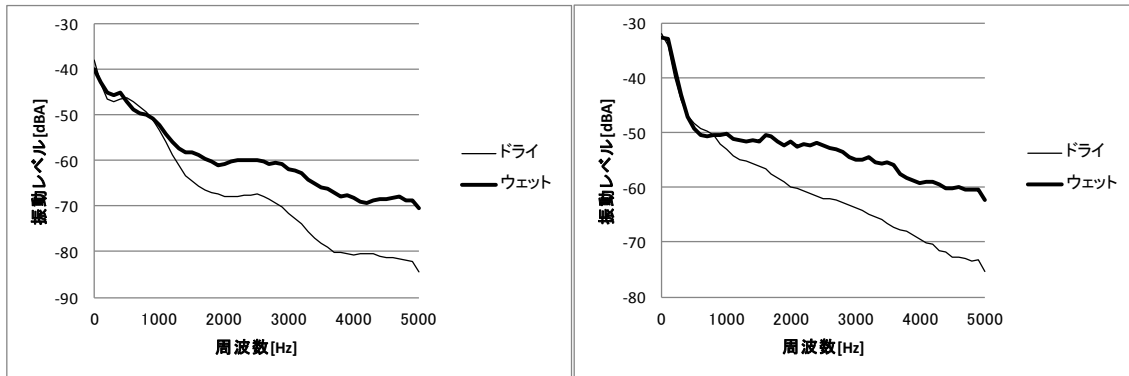
(c) 接地面領域の比較

(d) 蹴り出し領域の比較



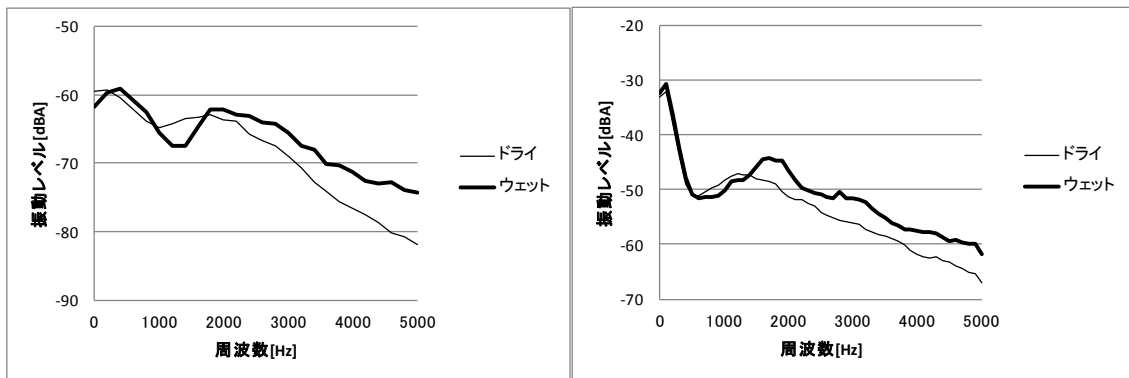
(e) 蹴り出し後領域の比較

図 13 ドライとウェットの FFT スペクトルに対する t 検定



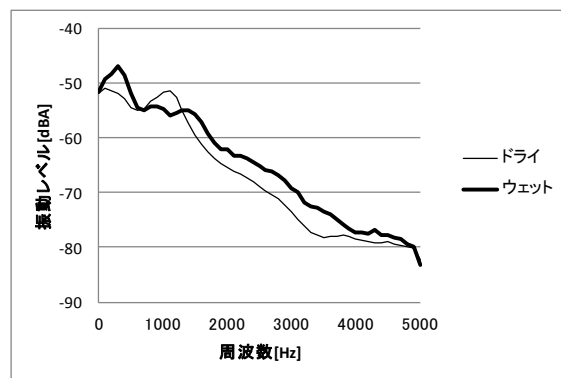
(a) 踏み込み前領域の比較

(b) 踏み込み領域の比較



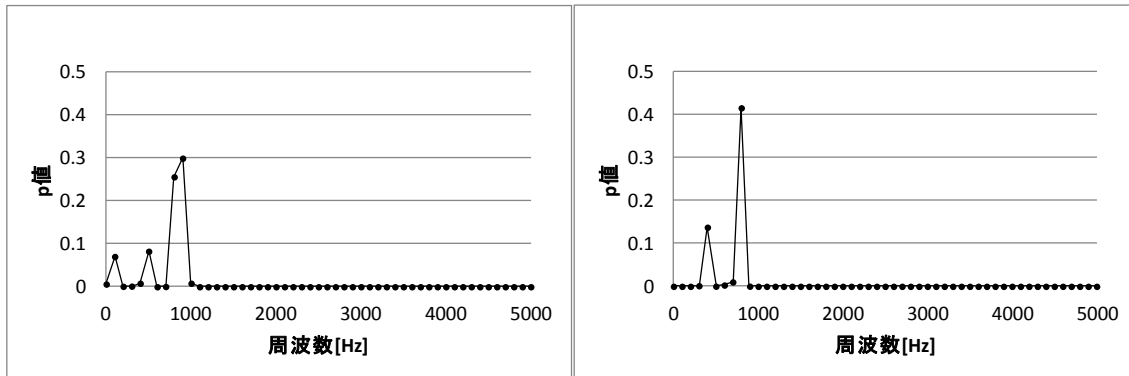
(c) 接地面領域の比較

(d) 蹴り出し領域の比較



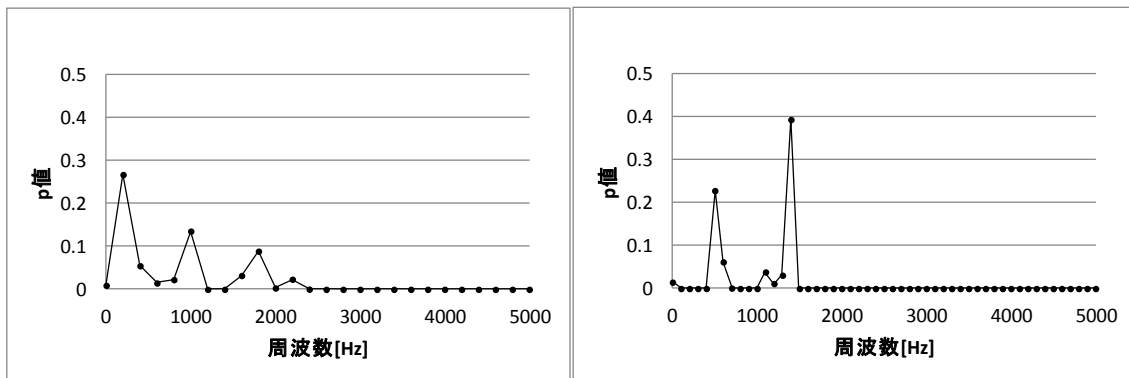
(e) 蹴り出し後領域の比較

図 14 各領域におけるドライとウェットの ARMA スペクトル比較



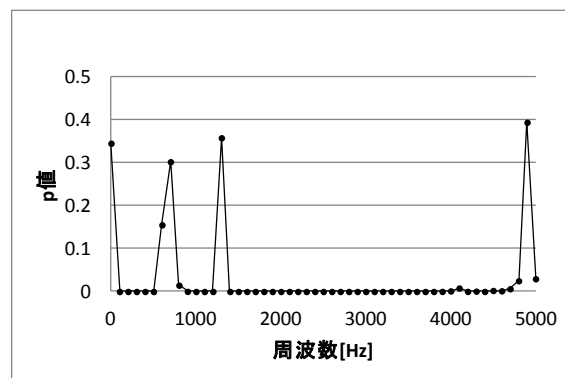
(a) 踏み込み前領域の比較

(b) 踏み込み領域の比較



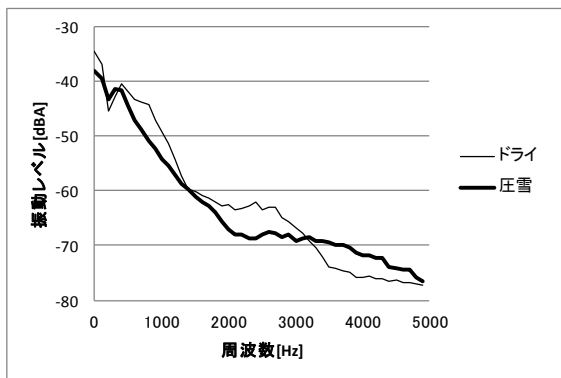
(c) 接地面領域の比較

(d) 蹴り出し領域の比較

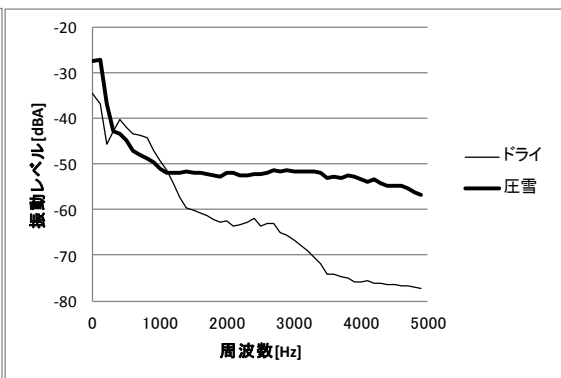


(e) 蹴り出し後領域の比較

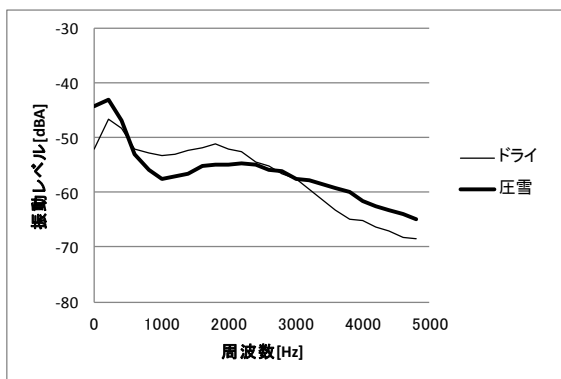
図 15 ドライとウェットの ARMA スペクトルに対する t 検定



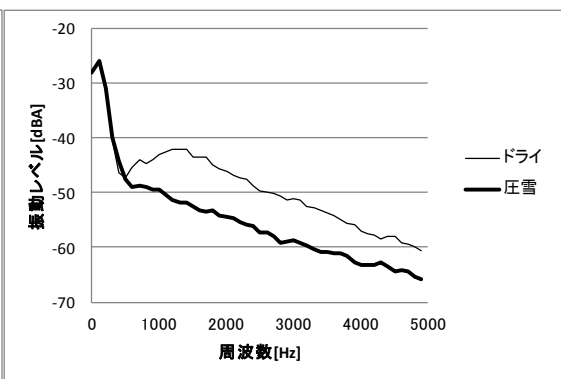
(a) 踏み込み前領域の比較



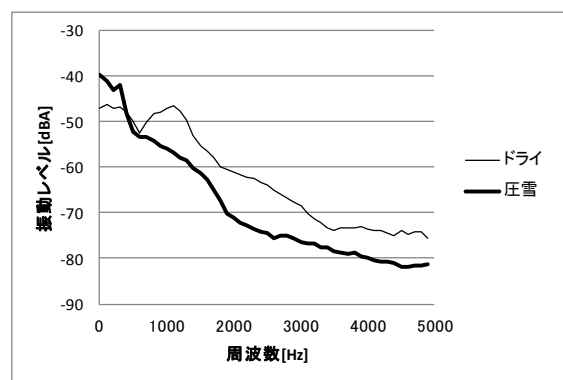
(b) 踏み込み領域の比較



(c) 接地面領域の比較

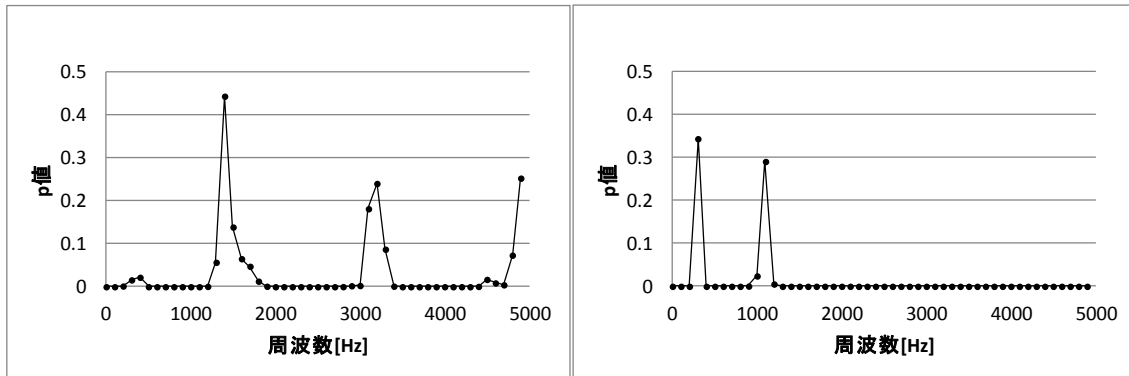


(d) 蹴り出し領域の比較



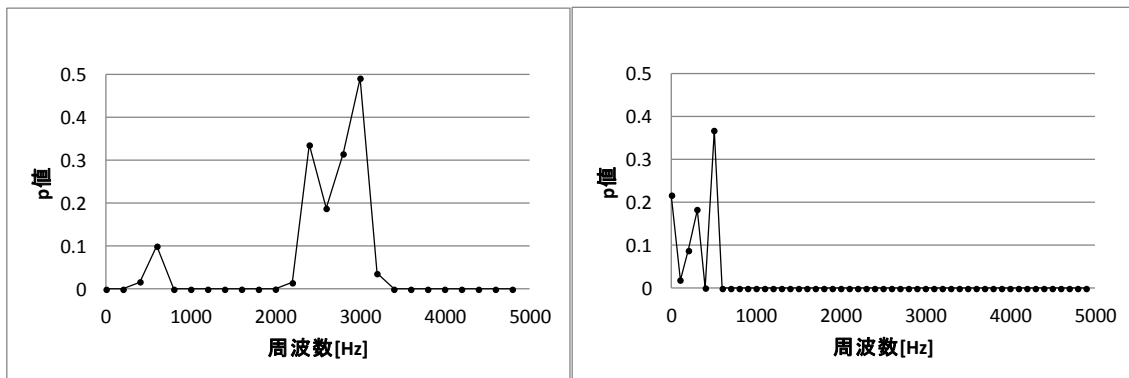
(e) 蹴り出し後領域の比較

図 16 各領域におけるドライと圧雪の FFT スペクトル比較



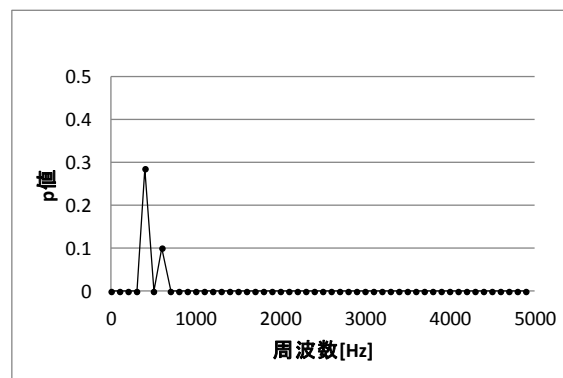
(a) 踏み込み前領域の比較

(b) 踏み込み領域の比較



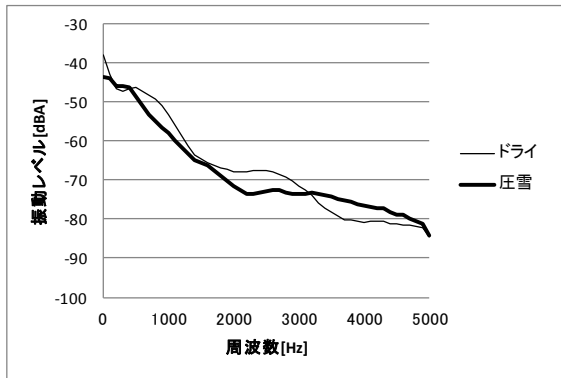
(c) 接地面領域の比較

(d) 蹴り出し領域の比較

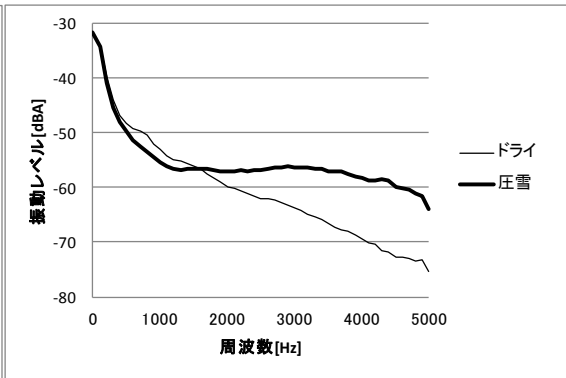


(e) 蹴り出し後領域の比較

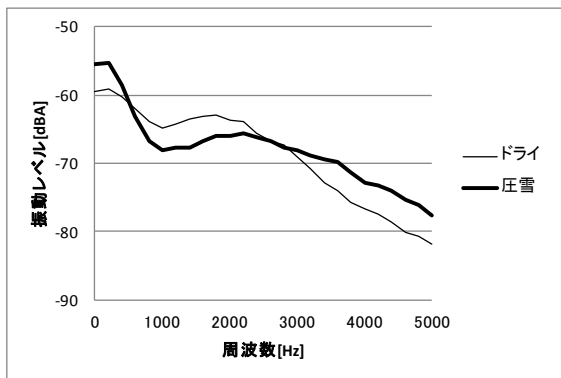
図 17 ドライと圧雪の FFT スペクトルに対する t 検定



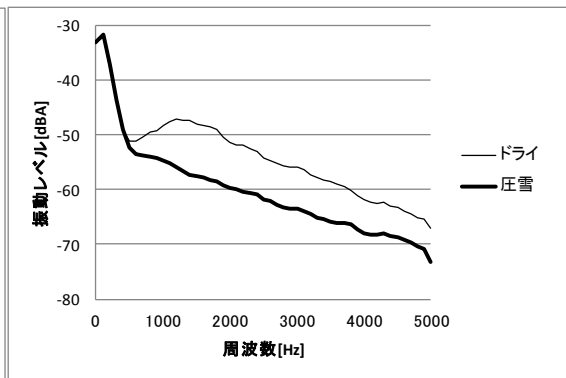
(a) 踏み込み前領域の比較



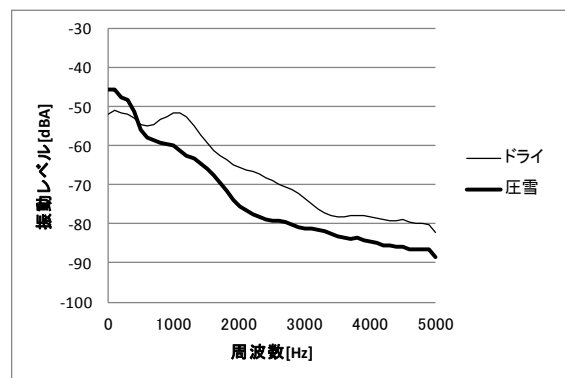
(b) 踏み込み領域の比較



(c) 接地面領域の比較

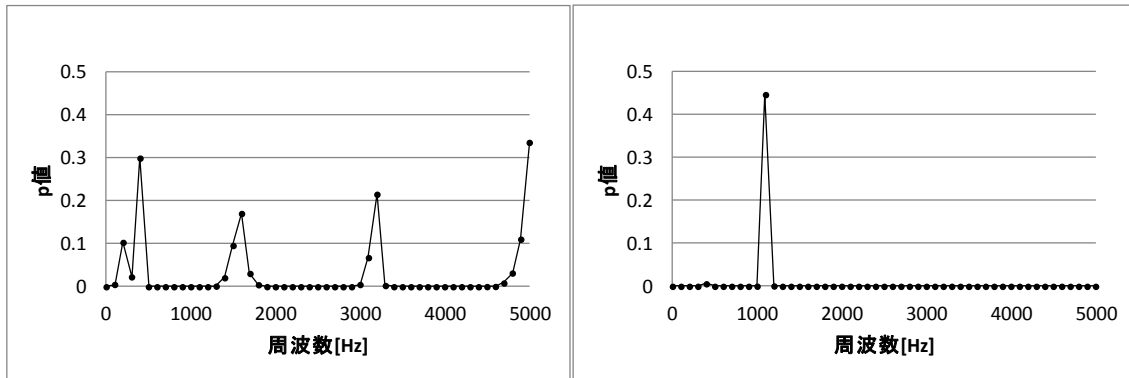


(d) 蹴り出し領域の比較



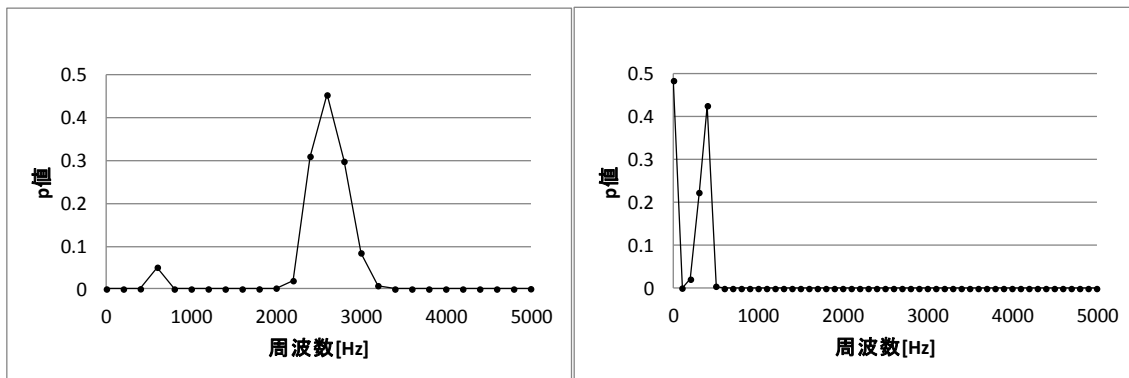
(e) 蹴り出し後領域の比較

図 18 各領域におけるドライと圧雪の ARMA スペクトル比較



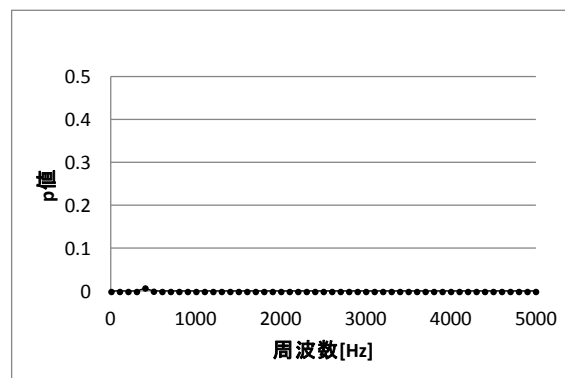
(a) 踏み込み前領域の比較

(b) 踏み込み領域の比較



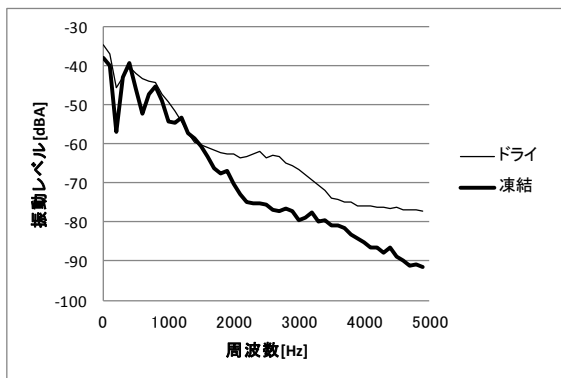
(c) 接地面領域の比較

(d) 蹴り出し領域の比較

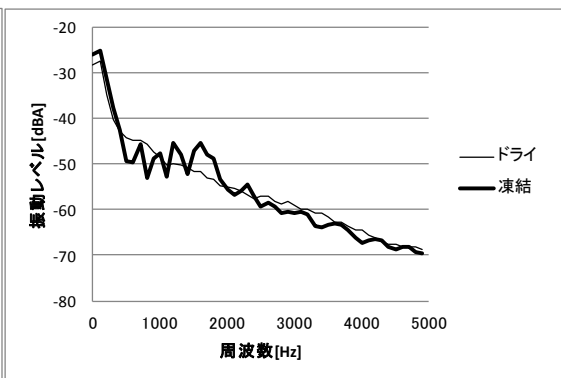


(e) 蹴り出し後領域の比較

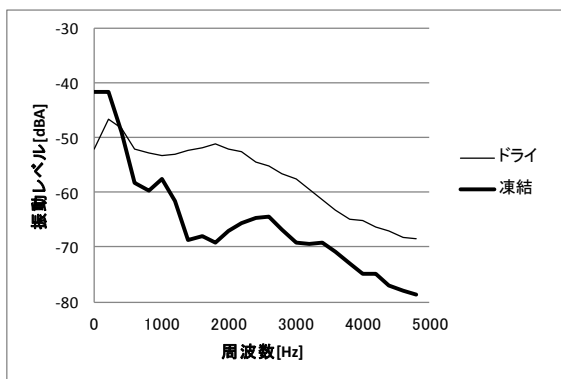
図 19 ドライと圧雪の ARMA スペクトルに対する t 検定



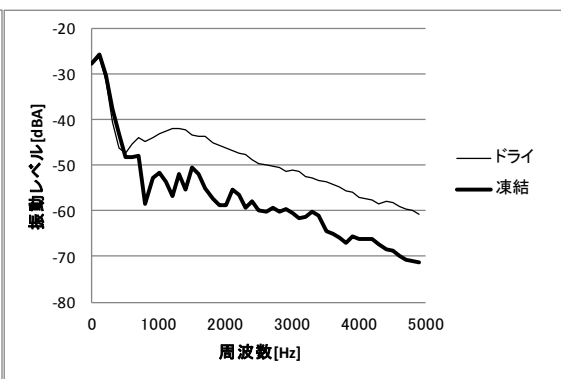
(a) 踏み込み前領域の比較



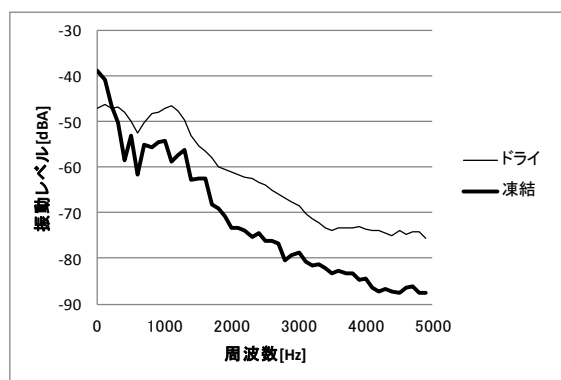
(b) 踏み込み領域の比較



(c) 接地面領域の比較

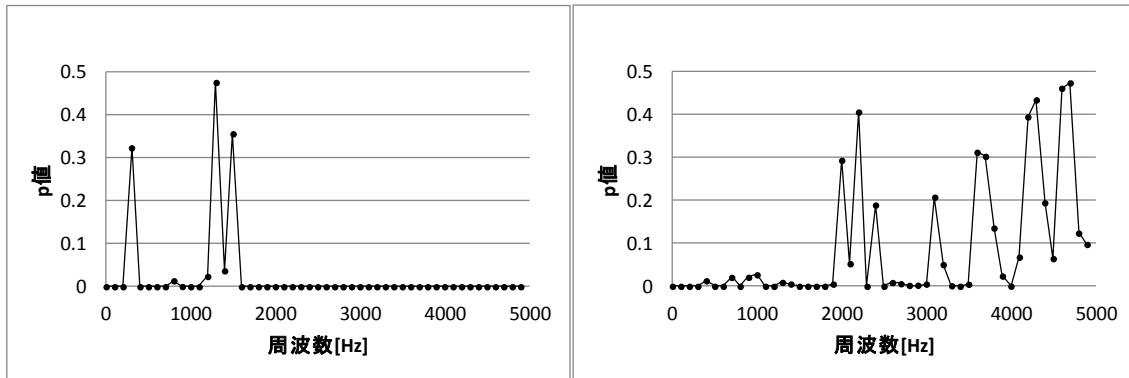


(d) 蹴り出し領域の比較



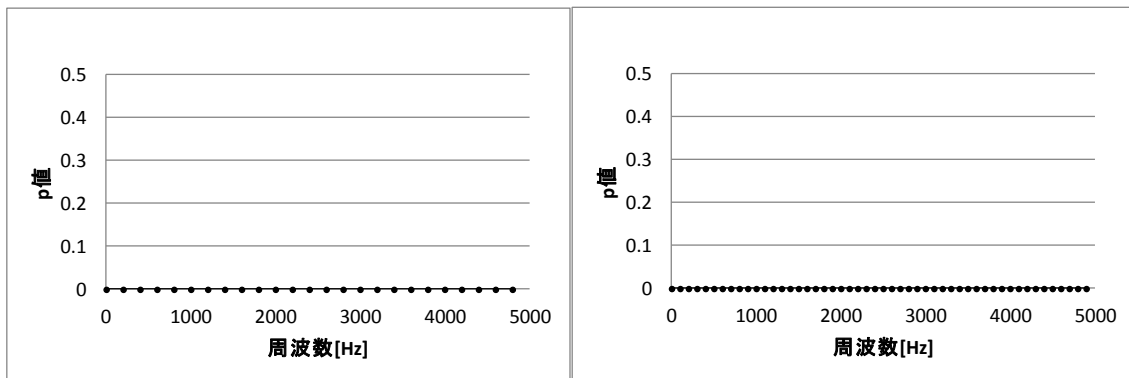
(e) 蹴り出し後領域の比較

図 20 各領域におけるドライと凍結の FFT スペクトル比較



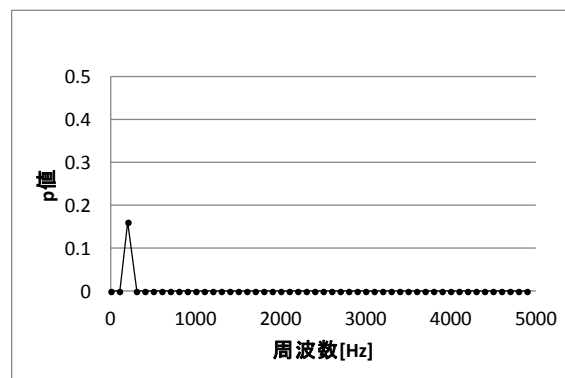
(a) 踏み込み前領域の比較

(b) 踏み込み領域の比較



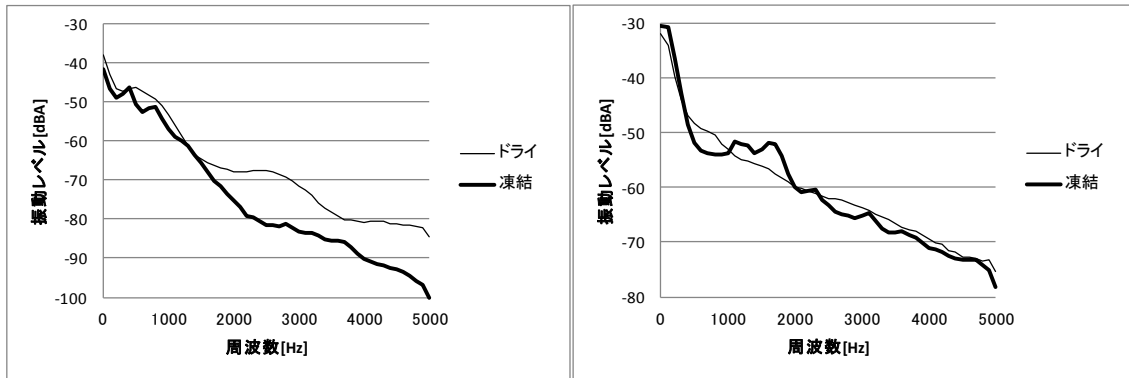
(c) 接地面領域の比較

(d) 蹴り出し領域の比較



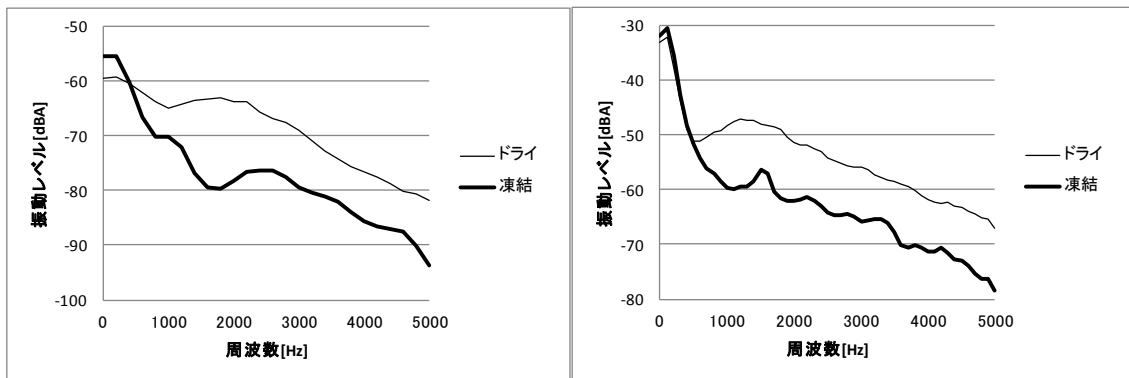
(e) 蹴り出し後領域の比較

図 21 ドライと凍結の FFT スペクトルに対する t 検定



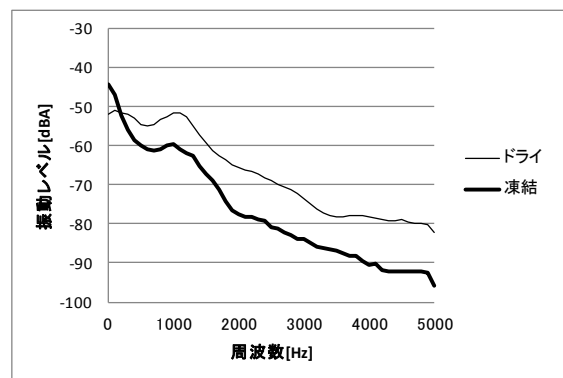
(a) 踏み込み前領域の比較

(b) 踏み込み領域の比較



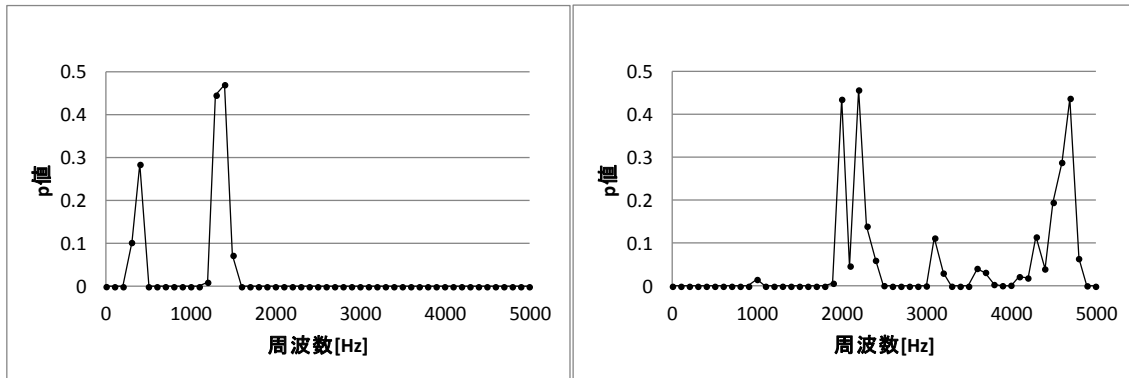
(c) 接地面領域の比較

(d) 蹴り出し領域の比較



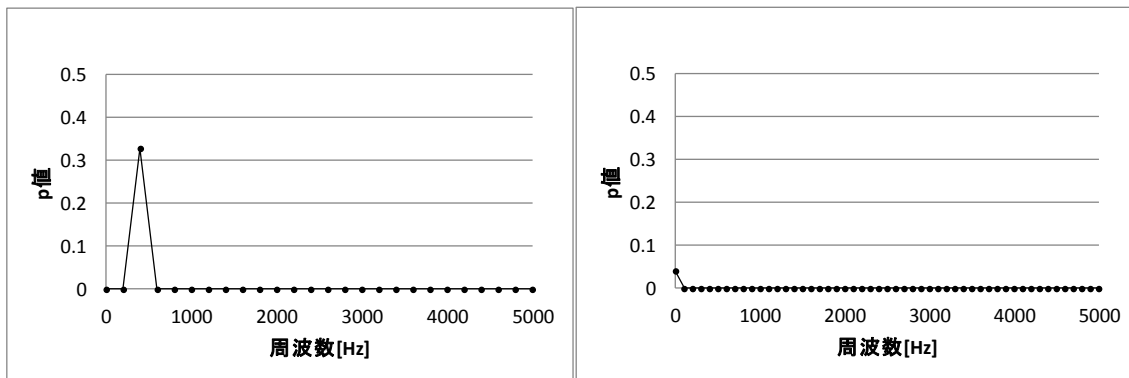
(e) 蹴り出し後領域の比較

図 22 各領域におけるドライと凍結の ARMA スペクトル比較



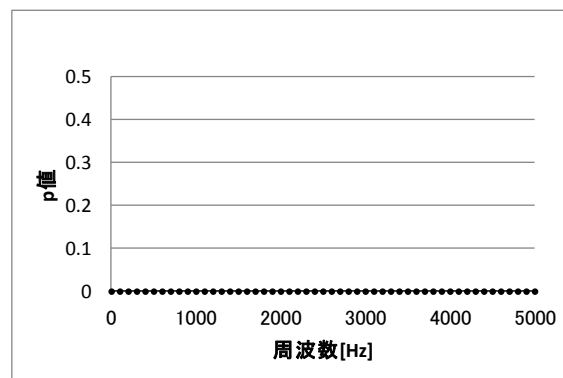
(a) 踏み込み前領域の比較

(b) 踏み込み領域の比較



(c) 接地面領域の比較

(d) 蹴り出し領域の比較



(e) 蹴り出し後領域の比較

図 23 ドライと凍結の ARMA スペクトルに対する t 検定

図 12 は各領域におけるドライアスファルトとウェットアスファルトの FFT スペクトルを比較したものである。スペクトルは 1 回転毎に算出し、その平均を取った。データ点数はドライアスファルトが 204 点、ウェットアスファルトが 66 点である。また、図 13 は図 12 を基に t 検定を行った結果であり、周波数ごとに算出した p 値を示している。ウェットアスファルトの波形の特徴出現メカニズムは、上述のようにタイヤと水膜の衝突によるものが支配的であるので、踏み込み前領域や踏み込み領域でドライアスファルトとの特徴差が大きい。その水膜の衝突による高周波成分が伝搬し、接地面領域や蹴り出し領域でも高周波域で特徴差がみられるが、その絶対量は踏み込み前領域に比べて小さい。図 14 および図 15 は、同様に、各領域におけるドライアスファルトとウェットアスファルトの ARMA スペクトルを比較したもので、およびその結果を基に t 検定を行った結果である。AR 次数、MA 次数はともに 15 とした。スペクトルの特徴は FFT と同様に、踏み込み前領域や踏み込み領域でドライアスファルトとの特徴差が大きく、接地面領域や蹴り出し領域でも高周波域で特徴差がみられるが、その絶対量は踏み込み前領域に比べて小さい。図 16 はドライアスファルトと圧雪路の FFT スペクトルを比較した結果である。圧雪のデータ点数は 180 点である。また図 17 は図 16 を基に t 検定を行った結果である。踏み込み領域では 2kHz 以上の高周波域で圧雪のレベルが上昇しており、これは摩擦係数が低下したこと、及び路面表面の細かな凹凸が増大しタイヤの接地性が低下したために、路面踏み込みの際に生じる滑りが増大して、滑りに起因する高周波振動が増大したためと考えられる。一方、蹴り出し領域や蹴り出し後領域では、逆に圧雪の高周波域が低下しているが、これは同様に摩擦係数低下に伴い、蹴り出し時に解放される剪断力が低下したため、蹴り出し時に励起されるゴムブロックの固有振動が減少したためと考えられる。図 18 および図 19 に示した ARMA スペクトルでも同様な傾向がみられる。図 20 はドライアスファルトと凍結路の FFT スペクトルを比較した結果である。凍結のデータ点数は 73 点である。また図 21 は図 20 の結果を基に t 検定を行った結果である。踏み込み領域のレベルに大きな違いはないが、接地面領域から後の領域では凍結路の 500Hz 以上のレベルが低い。このことは図 22 および図 23 に示した ARMA スペクトルでも同様である。この要因は上述の圧雪路面の特徴と同様に、蹴り出し時に励起されるゴムブロックの固有振動が減少したためと考えられる。

このように、タイヤ振動波形の特徴は、路面状態に応じて、特定の周波数帯に現れる一方、路面踏み込みや接地、蹴り出しといったタイヤの接地挙動に応じて、

時系列的にも変化するので、本研究が目的とする正確な路面状態判別のために、これらを考慮したタイヤ振動波形の特徴の定量化を行うこと、およびその特徴を用いて適切にモデリングする手法を構築することが課題である。

3.3 タイヤ振動波形の特徴の定量化法

本研究では上述のように周波数成分に現れるタイヤ振動の特徴を、デジタルフィルタを用いた手法、および Cepstrum 係数によって定量化した。Cepstrum [21] [22]は、音声認識等の分野で適用されている信号処理手法であり、ある時系列から得たスペクトルを信号とみなして更にスペクトルを求める手法である。3.1 節で説明したように、高 μ 路面走行時に対して低 μ 路面走行時のタイヤ振動では、蹴り出し後振動波形スペクトルのブロック固有振動数に対応する周波数帯に現れるピークの高さや幅などの形状が変化するという特徴を有する。このことが一般にスペクトルの包絡成分と微細構造成分に分離して特徴付けられる音声波形に類似していると考え、音声認識等で用いられる LPC Cepstrum を上記タイヤ振動の特徴を定量化する手法として採用した。一般に音声認識では、人間の聴覚の知覚特性にあわせたメル尺度 [23]と呼ばれる周波数軸を考えるが、本研究では対象がタイヤ振動であるため、リニアな周波数軸を採用した。本節では具体的な特徴定量化手法について説明する。

まず前処理として、図 24 に示すように波形を所定の窓の長さ、フレーム周期で窓掛けする。デジタルフィルタを用いた手法では、表 2 に示す特性のフィルタを透過したそれぞれの波形の時系列のパワー値の平均値を特徴量とした。つまり t 番目のフレームにおける特徴量 x は次式で与えられる。

$$x_{ts} = \frac{1}{N} \sum_{i=1}^N G_{tsi}^2 \quad (3-3-1)$$

s はフィルタ特性のインデックスの集合、 G はフィルタ透過後の波形の時系列、 N は窓に含まれるデータの数である。本研究では法定上限速度の時速 100km/h でも 3.1 及び 3.2 節で述べたタイヤ振動波形の時系列的な特徴を捉えるため、窓長さを 3[msec]、フレーム周期を 2[msec]とし、窓関数にはハミング窓を用いた。データ収録は 10kHz のサンプリングレートで行ったので、 N は 30 である。また本研究

では表 2 に示す 6 つの特性の異なるフィルタを使用しているので、特徴ベクトルの次元数は 6 である。

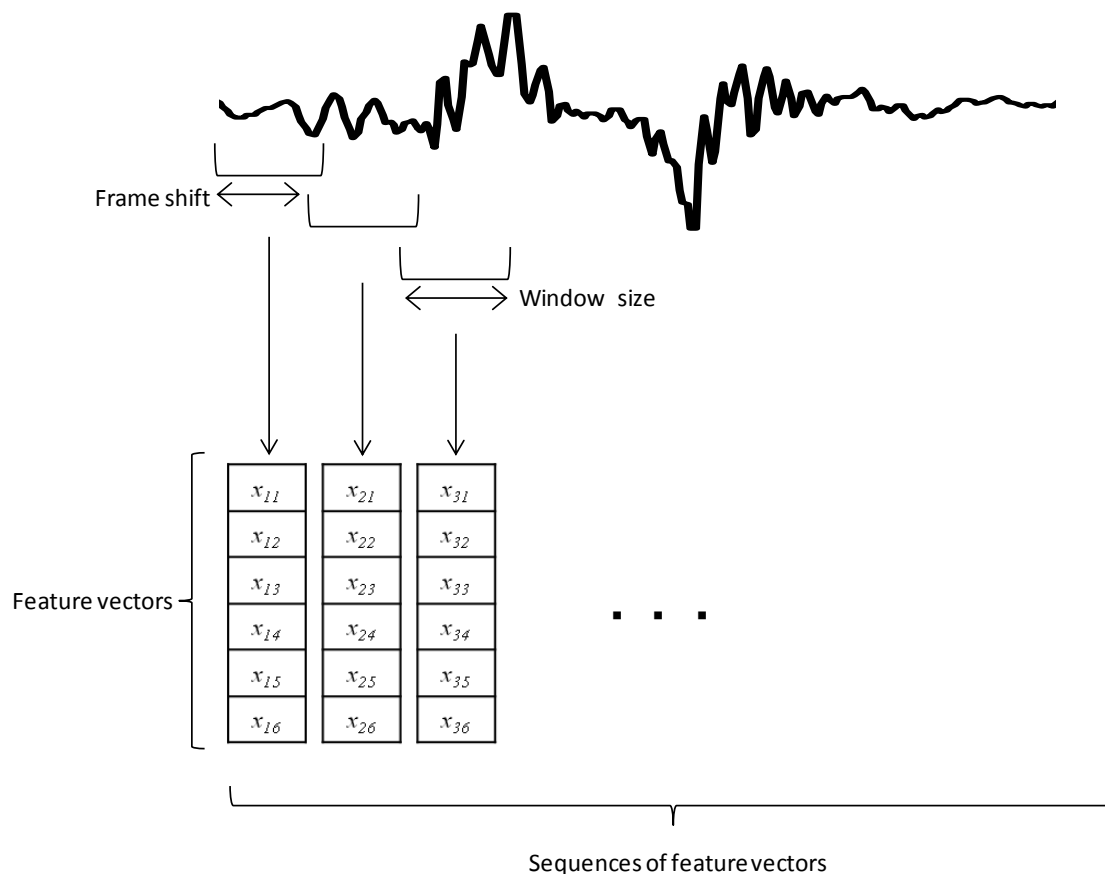


図 24 タイヤ振動波形の特徴定量化の過程

Type	FIR/IIR	Low cutoff freq[Hz]	High cutoff freq[Hz]	Order
Low-pass	IIR	500	-	5
Band-pass	IIR	500	1000	5
Band-pass	IIR	1000	2000	5
Band-pass	IIR	2000	3000	5
Band-pass	IIR	3000	4000	5
Band-pass	IIR	4000	5000	5

表 2 デジタルフィルタの特性

一方 LPC Cepstrum はまず以下の線形予測モデルに関して線形予測係数を最尤法によって求める．

$$x_s = \sum_{i=1}^m a_i x_{s-i} \quad (3-1-2)$$

ただし x_s は時刻 s における入力時系列の値， a は線形予測係数， m は線形予測次数である．この係数列： a を入力信号とみなして，さらに自己相関係数を求めることで LPC Cepstrum 係数： c を以下のように算出する．

$$c_n = -a_n - \frac{1}{n} \sum_{i=1}^{n-1} (n-i) a_i c_{n-i} \quad (3-1-3)$$

ただし， n はケプストラム次数である．本研究では $m=15$ ， $n=7$ とし，この 7 個のケプストラム係数にフレームのパワー値を加えた 8 個の特徴量について，それぞれ 1 次差分と 2 次差分をとり，計 24 次元の特徴ベクトルとした．

本節では解くべき技術課題の一つであるタイヤ振動波形の特徴定量化法について述べた．次章および第 5 章では上述の特徴量を用いたタイヤ振動波形のモデル化手法とそれに基づく路面判別方法について説明する．まず，次章では HMM に基づく手法について説明する．

第4章 隠れマルコフモデルによるタイヤ振動のモデル化と路面状態判別方法

本章ではまず HMM の基礎を概説し，その後タイヤ振動のモデル化，およびそれを基にした路面状態判別方法について具体的に説明する．

4.1 隠れマルコフモデル

HMM は状態空間モデルの潜在変数がマルコフ性を有し，且つ離散変数であるとき，観測値は対応する潜在変数の状態に条件づけられると仮定するモデルである [24]．状態の遷移は確率的に表現されるため，時間軸上で伸縮しうる信号のパターン認識に適している手法である．近年実用化され急速に普及してきた音声認識や自然言語処理では，時間や速さが異なる信号を比較する必要があるため，HMM を応用した手法が数多く研究され発展してきた [25]．本研究では，前章で述べたように車輪速などによって動的に変化し，且つ時間伸縮するタイヤ振動を HMM でモデル化する検討を行った．本節では HMM の基本と構成方法について述べる．

4.1.1 マルコフモデル [26]

系列データを扱う場合，観測値間の相関を捉えることでデータの構造をうまくモデル化することができる．つまり独立同分布の仮定を緩めることによってモデルの柔軟性を高めることができる．その最も単純なモデルの一つがマルコフモデルである．

T 個の観測値からなる系列 $O=\{o_1, o_2, \dots, o_T\}$ が与えられたときの同時分布は確率の乗法定理を用いて，

$$P(o_1, o_2, \dots, o_T) = P(o_1) \prod_{t=2}^T P(o_t | o_1, o_2, \dots, o_{t-1}) \quad (4-1-1)$$

と表すことができる．このとき各観測値がその直前の観測値以外から独立であると仮定すると，図 25 に示す一次マルコフ連鎖を得る．

$$P(o_1, o_2, \dots, o_T) = P(o_1) \prod_{t=2}^T P(o_t | o_{t-1}) \quad (4-1-2)$$

このモデルでは各観測値は直前の観測値にのみ条件づけられているが，実際の問題において，より過去の観測値からの影響も加味する必要がある場合には高次のマルコフ連鎖を考える．例えば二次のマルコフ連鎖の同時確率は

$$P(o_1, o_2, \dots, o_T) = P(o_1)P(o_2 | o_1) \prod_{t=2}^T P(o_t | o_{t-1}, o_{t-2}) \quad (4-1-3)$$

となる．同様にして 4-3 式を M 次マルコフ連鎖への拡張も可能である．これをさらに確率の乗法定理を用いて展開すると， T 個すべての観測値を与えたときの観測値： o_T の条件付き確率は次式で表される．

$$P(o_T | o_1, o_2, \dots, o_{T-1}) = P(o_T | o_{T-1}, o_{T-2}, \dots, o_{T-M}) \quad (4-1-4)$$

このように M 次のマルコフモデルでは，ある観測値はそれ以前の M 個の観測値に条件づけられている． M の値を増やせばモデルの柔軟性は上がるが，その代償としてモデルパラメータの数は急激に増大するため， M の値は問題に応じて適切に決定する必要がある，

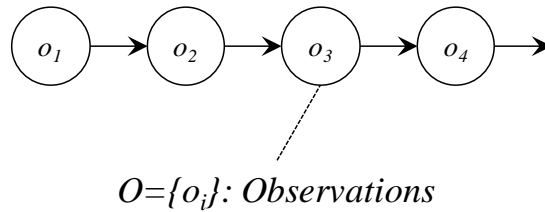


図 25 一次のマルコフ連鎖

4.1.2 隠れマルコフモデルの定式化 [24] [26]

HMMは状態を確率的に切替えることによって，非定常な信号を局所的に定常な信号の集合として扱うことができるモデルであり，音声認識 [27] [28] [29] [30]や文字認識 [31] [32]，DNA配列の解析 [33] [34]等に広く応用されている．

4.1.1では観測値のマルコフ連鎖について述べたが，それぞれの観測値に対応する潜在変数を導入し，マルコフ連鎖を構成するのが潜在変数であると仮定すると状態空間モデルを得る．HMMはこの状態空間モデルの潜在変数が離散変数である特殊な場合と解釈することができる．この時観測変数は各状態毎に定義された出力確率関数に従い出力されるシンボルのみであり，出力シンボルのみを観測しても各時刻の状態は確率的にしか観測できない．HMMのパラメータを θ ，状態遷移

系列を $X = \{x_1, x_2, \dots, x_T\}$ とすると, θ が与えられた下での観測値の系列 $O = \{o_1, o_2, \dots, o_T\}$ の尤度は,

$$P(O|\theta) = \sum_X P(O, X|\theta) = \sum_X P(O|X, \theta) P(X|\theta) \quad (4-1-5)$$

と表せる. ここで時刻 t における状態 $x(t)$ で観測値 o_t を出力する確率関数を $b_{x(t)}(o_t)$ とすると $P(O|X)$ は以下のように表せる.

$$P(O|X) = \prod_{t=1}^T b_{x(t)}(o_t) \quad (4-1-6)$$

観測変数 o_t は離散変数でも連続変数でもよく, 出力確率関数には様々な条件付き分布を用いることができる. 本研究では, 音声認識で一般的に用いられる GMM (Gaussian Mixture Model, 混合ガウス分布) [35] [36] を採用した.

$$b_{x(t)}(o_t) = \sum_{m=1}^M c_{x(t)m} N(o_t; \mu_{x(t)m}, \Sigma_{x(t)m}) \quad (4-1-7)$$

$$\int b_{x(t)}(o_t) do = 1 \quad (4-1-8)$$

ただし, c は GMM の混合比, M は GMM の混合数, $N(\cdot; \mu, \Sigma)$ は平均 μ , 分散共分散行列 Σ の多変量ガウス分布である.

また状態系列を $S = \{s_i\}$ とし, i 番目の状態から j 番目へ遷移する確率を a_{ij} とすると $P(X)$ は

$$P(X) = \prod_{t=1}^{T-1} a_{x(t)x(t+1)} \quad (4-1-9)$$

$$\sum_i a_{ij} = 1 \quad (4-1-10)$$

と表せる.

さらに初期状態確率 π_i は,

$$\pi_i = P(x(1) = s_i) \quad (4-1-11)$$

$$\sum_i \pi_i = 1 \quad (4-1-12)$$

である．以上より，初期状態確率の集合を $\pi=\{\pi_i\}$ ，状態遷移確率の集合を $A=\{a_{ij}\}$ ，出力確率分布の集合を $B=\{\mu,\Sigma\}$ とすると，HMM のパラメータは $\theta=(\pi,A,B)$ である．
よってモデル： M が与えられた下での尤度は式 4-1-5 に式 4-1-6 と式 4-1-9 を代入して以下のように得られる．

$$\begin{aligned} P(O|M) &= P(O|\theta) = \sum_X \left(\prod_{t=1}^T b_{x(t)}(o_t) \prod_{t=1}^{T-1} a_{x(t)x(t+1)} \right) \\ &= \sum_X \left(a_{x(0)x(1)} \prod_{t=1}^T b_{x(t)}(o_t) a_{x(t)x(t+1)} \right) \end{aligned} \quad (4-1-13)$$

図 26 に HMM のグラフ構造を示す．状態数は開始状態，終了状態を含めて 5 状態あり，潜在変数が 2 次のマルコフ性を有している構造である．

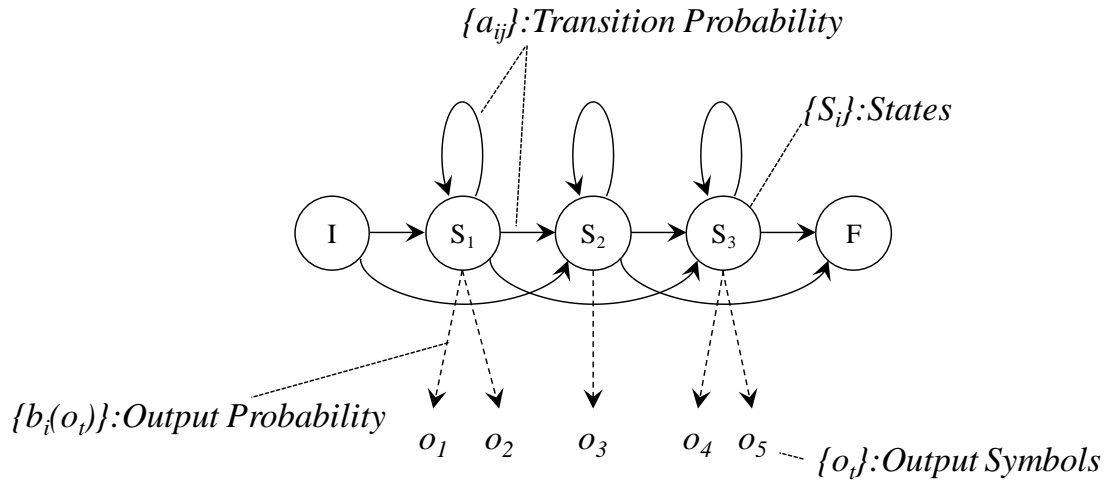


図 26 HMM のグラフ構造

4.1.3 EM アルゴリズム

前項で説明した HMM の尤度関数を最大化するパラメータ $\theta=(\pi,A,B)$ を最尤推定によって求める効率的な枠組みとして EM(Expectation Maximization) アルゴリズムがある．EM アルゴリズムは反復法の一つであり，E(Expectation：期待値)

ステップで、現在のモデルパラメータ集合： θ^l を用いて新たなパラメータ集合： θ の関数としてモデルの尤度の期待値： $Q(\theta, \theta^l)$ を計算する．その後 **M**(Maximization：最大化)ステップで $Q(\theta, \theta^l)$ を最大化する．このステップを交互に繰り返すことで最尤推定もしくは尤度関数の極大点を得られる．

E ステップでは、モデルの対数尤度の期待値を次のように計算する．

$$Q(\theta, \theta^l) = \sum_X P(X | O, \theta^l) \ln P(O, X | \theta) \quad (4-1-14)$$

ここで、 $P(X|O, \theta^l)$ は潜在変数の事後分布である． $P(O, X|\theta)$ は潜在変数と観測変数の同時確率分布であり、

$$P(O, X | \theta) = P(x_1 | \pi) \left\{ \prod_{n=2}^N P(x_n | x_{n-1}, A) \right\} \prod_{m=1}^N P(o_m | x_m, B) \quad (4-1-15)$$

と表される．ここで時刻 t で状態 s_j にいる確率を $L(s_{tj})$ ，時刻 $t-1$ で状態 s_i ，時刻 t で状態 s_j にいる同時確率を $H(s_{t-1,i}, s_{tj})$ とし、式(4-1-15)を式(4-1-14)に代入すると次式を得る．

$$\begin{aligned} Q(\theta, \theta^l) = & \sum_{i=1}^S L(s_{1i}) \ln \pi_i + \sum_{t=2}^T \sum_{i=1}^S \sum_{j=1}^S H(s_{t-1,i}, s_{tj}) \ln a_{ij} \\ & + \sum_{t=1}^T \sum_{j=1}^S L(s_{tj}) \ln p(o_t | B) \end{aligned} \quad (4-1-16)$$

M ステップでは、この式(4-1-16)を最大化するような各パラメータを求める． π および A に関しては式(4-1-10)および式(4-1-12)に示すように、それぞれの和が 1 になるという制約があるため、ラグランジュ未定乗数法を用いて、次式のように求められる．

$$\pi_i = \frac{L(s_{1i})}{\sum_{j=1}^S L(s_{1j})} \quad (4-1-17)$$

$$a_{ij} = \frac{\sum_{t=2}^T H(s_{t-1,i}, s_{tj})}{\sum_{k=1}^S \sum_{t=2}^T H(s_{t-1,i}, s_{tk})} \quad (4-1-18)$$

一方，本研究では出力確率関数にガウス分布を採用したので， $p(o_t|B) = N(x|\mu, \Sigma)$ となる．これを式(4-1-16)に代入すると，パラメータ μ と Σ に関しそれぞれ独立に最大化できるので，以下のように求められる．

$$\mu_i = \frac{\sum_{t=1}^T L(s_{ti}) o_t}{\sum_{t=1}^T L(s_{ti})} \quad (4-1-19)$$

$$\Sigma_i = \frac{\sum_{t=1}^T L(s_{ti}) (o_t - \mu_i)(o_t - \mu_i)^T}{\sum_{t=1}^T L(s_{ti})} \quad (4-1-20)$$

結局尤度関数の期待値を最大化する問題は $L(s_{ij})$ と $H(s_{t-1,i}, s_{ij})$ を効率的に求める問題に帰着する．その方法として，よく知られたものに **Baum-Welch** アルゴリズムまたはフォワード-バックワードアルゴリズムと呼ばれるものがある． $L(s_{ij})$ 及び $H(s_{t-1,i}, s_{ij})$ はその定義とベイズの定理，および確率の乗法定理より，

$$\begin{aligned} L(s_{ij}) &= P(x(t) = s_j \mid O, M) \\ &= \frac{P(O, x(t) = s_j \mid M)}{P(O \mid M)} \end{aligned} \quad (4-1-21)$$

$$\begin{aligned} H(s_{t-1,i}, s_{ij}) &= P(x(t-1) = s_i, x(t) = s_j \mid O, M) \\ &= \frac{P(O \mid x(t-1) = s_i, x(t) = s_j, M) P(x(t-1) = s_i, x(t) = s_j \mid M)}{P(O \mid M)} \\ &= P(o_1, \dots, o_{t-1} \mid x(t-1) = s_i, M) P(o_t \mid x(t) = s_j, M) \\ &\quad \times P(o_{t+1}, \dots, o_T \mid x(t) = s_j, M) P(x(t) = s_j \mid x(t-1) = s_i, M) \\ &\quad \times P(x(t-1) = s_i \mid M) \times \frac{1}{P(O \mid M)} \end{aligned} \quad (4-1-22)$$

と表される．ここで前向き確率 α_{jt} と後ろ向き確率 β_{jt} を導入する． α_{jt} は，時系列 $\{o_1, o_2, \dots, o_T\}$ のある時刻 t までの $\{o_1, o_2, \dots, o_t\}$ を観測したときの，状態 s_j に存在する確率であり， β_{jt} はある時刻 t から T までの時系列 $\{o_t, o_{t+1}, \dots, o_T\}$ が観測されたときに，時刻 t で状態 s_j に存在する確率であって，それぞれ次のように定義する．

$$\alpha_{jt} = P(o_1, \dots, o_t, x_t = s_j \mid M) \quad (4-1-23)$$

$$\beta_{jt} = P(o_t, \dots, o_T \mid x_t = s_j, M) \quad (4-1-24)$$

$$\alpha_{jt} \beta_{jt} = P(O, x(t) = s_j \mid M) \quad (4-1-25)$$

式(4-1-23)~(4-1-25)を，式(4-1-21)および式(4-1-22)に代入すると， $L(s_{ij})$ 及び $H(s_{t-1,i}, s_{ij})$ は

$$L(s_{ij}) = \frac{\alpha_{jt} \beta_{jt}}{P(O \mid M)} \quad (4-1-26)$$

$$H(s_{t-1,i}, s_{ij}) = \frac{\alpha_{it-1} \beta_{jt} b_j(o_t) a_{ij}}{P(O \mid M)} \quad (4-1-27)$$

と表される．式(4-1-22)および式(4-1-23)に対し条件付き独立性と確率の加法・乗法定理を使うと， α_{jt} および β_{jt} はそれぞれ，

$$\begin{aligned} \alpha_{jt} &= \left[\sum_{i=2}^{S-1} \alpha_{j,t-1} P(x_t \mid x_{t-1}) \right] P(o_t \mid x_t) \\ &= \left[\sum_{i=2}^{S-1} \alpha_{j,t-1} a_{ij} \right] b_j(o_t) \end{aligned} \quad (4-1-28)$$

$$\begin{aligned} \beta_{jt} &= \sum_{i=2}^{S-1} \beta_{i,t+1} P(x_{t+1} \mid x_t) P(o_t \mid x_t) \\ &= \sum_{i=2}^{S-1} \beta_{i,t+1} a_{ij} b_j(o_{t+1}) \end{aligned} \quad (4-1-29)$$

という再帰式の形で表される．

以上説明してきたEMアルゴリズムを用いたHMMの学習を行う過程をまとめる

と以下のようになる．

1. パラメータ θ の初期値を設定する
2. 前向き確率 α_{jt} と後ろ向き確率 β_{jt} に関する再帰を実行し（式4-1-28, 式4-1-29）, その結果から $L(s_{ij})$ 及び $H(s_{t-1,i}, s_{ij})$ を求める（式4-1-26, 式4-1-27）
3. 新たに求めた $L(s_{ij})$ 及び $H(s_{t-1,i}, s_{ij})$ から, パラメータを更新する（式4-1-17～式4-1-20）
4. 上記をある収束条件が満たされるまで繰り返す．

このように本節ではHMMの基礎とそのパラメータを学習によって求める方法について説明した．次章ではそれらの手法を使って本研究テーマへの具体的な適用方法について述べる．

4.2 HMM によるモデル化と判別方法

本節では走行中のタイヤ振動波形の特徴を, 4-1 節で述べた HMM でモデル化する手法の説明をする．本研究で取り扱う問題は、タイヤ 1 回転分の波形データが入力されたとき、路面状態を 1 回推定する判別問題である．本研究では判別方法の異なる 2 つの手法を提案する．

＜提案手法 1 の計算フロー＞

1. タイヤ振動波形入力
2. デジタルフィルタ, または LPC ケプストラムを用いて波形の特徴を定量化する
3. 学習データから予めパラメータを求めておいた各路面状態に対応するモデルの尤度をそれぞれ算出する
4. 最も尤度が高いモデルに対応する路面状態に判別する

提案手法 1 では, まず 3 章で述べた手法を用いて, タイヤ振動波形の特徴を定量化する．3 ステップ目で予め路面状態毎に構成していたモデルに対する尤度を算出する．詳細には, ドライアスファルト, ウェットアスファルト, 圧雪, 凍結および無情報状態を表す Sil (silent) に対応する 5 つの HMM のパラメータ集合: $\theta = [\pi, \mu, \Sigma, \{a_{x(i)x(j)}\}]$ を, 4.1 節で述べた手法を用いて, 学習用データから求める．実際の波形には路面状態変化に伴う特徴がほとんどない接地面外の波形も含まれ

ているので、その波形もモデル化するために無情報状態を表す **Sil** の **HMM** も含めた。

図 27 に正解ラベル付けの例を示す。**Road** はドライアスファルト、ウェットアスファルト、圧雪、凍結のいずれかに対応する。タイヤ振動は上述のように、路面を踏みこんで、接地状態が続き、蹴り出すという動作の順序は不変である。そこで、本研究では路面に接地／非接地したタイヤの振動を図 28 に示すような **left-to-right** モデルで表す。**HMM** を構成する上で、状態数をいくつにすればよいかが問題となるが、これはデータに基づいて決定する以外にない。状態数が少なすぎれば、データの構造を適切に表現できなくなり精度は下がる。一方、多すぎればモデルパラメータ数の増大に伴う計算コストの増大を招くばかりでなく、過学習につながって精度を下げる要因ともなる [26]。タイヤ振動は第 3 章で説明したように少なくとも、路面踏み込み、接地、路面蹴り出しの 3 つの接地状態に分けられると考えられる。また水膜がある場合には踏み込み前に特徴が表れ、滑りやすい路面では蹴り出しの後に特徴が現れることが分かっているので、本研究では開始、終了状態を含めて 5, 6, 7 状態の **HMM** でモデル化することとした。**HMM** の学習は 4.1.3 で説明した **Baum-Welch** アルゴリズムで行った。なお、**GMM** の混合数は 1, 2, または 3 とした。

また接地面近傍の波形をモデル化した **Road** が、無情報状態のモデルである **Sil** に挟まれた構造を考える。この構造を、図 29 に示すような **HMM** のネットワークとして構成する。つまり **Sil** の **HMM** と **Road** の **HMM** をつなぎ合わせて、一つのモデルとする。ただし、**Sil** は 0 回以上繰り返すものとし、つまり高速走行時に想定される無情報区間が全く無い場合にも、低速走行時や停止時に想定される無情報区間が長く続く場合にも対応できるようにした。走行中のリアルタイム判別の場合には、連続的にタイヤ振動データが入力されるので、実際には図 29 の **HMM** のネットワークにおいて、右側の **Sil** の最終状態から左側の **Sil** の開始状態へ戻る遷移を考える必要がある。本検討では 1 回転ごとに切り出した波形を予め用意したため、この遷移を持たない **HMM** のネットワークを用いた。上記のように路面状態ごとに構築したモデルについて、**Viterbi** アルゴリズム [37]によって尤度の近似値

$$\hat{P}(O|M) = \max_X \left\{ a_{x(o)x(1)} \prod_{t=1}^T b_{x(t)}(o_t) a_{x(t)x(t+1)} \right\} \quad (4-1-1)$$

を算出し，4 ステップ目でそれらの尤度を比較して，最も高い尤度を示すモデルに対応する路面状態であると判別する．

＜提案手法 2 の計算フロー＞

1. タイヤ振動波形入力
2. デジタルフィルタ，または LPC ケプストラムを用いて波形の特徴を定量化する
3. 学習データから予めパラメータを求めておいた各路面状態に対応するモデル，およびそれぞれの路面状態以外の 3 つの路面状態を統合したモデルの尤度をそれぞれ算出する
4. ある一つの路面状態に対応するモデルと，それ以外の 3 つの路面状態を統合したモデルの尤度を比較する．これを 4 種の路面状態全てについて行い，得られた結果から路面状態を判別する

提案手法 1 と同様に，まず 3 章で述べた手法を用いて，タイヤ振動波形の特徴を定量化する．3 ステップ目で各路面状態に対応するモデル，およびそれぞれの路面状態以外の 3 つの路面状態を統合したモデルに対する尤度を算出する．詳細には，ドライアスファルト，ウェットアスファルト，圧雪，凍結，および無情報状態を表す Sil (silent) に対応する HMM に加えて，ドライアスファルト以外の 3 つの路面状態をまとめたモデル，ウェットアスファルト以外の 3 つの路面状態をまとめたモデル，圧雪以外の 3 つの路面状態をまとめたモデル，凍結以外の 3 つの路面状態をまとめたモデルの合計 9 つの HMM について，パラメータ集合： $\theta=[\pi, \mu, \Sigma, \{a_{x(i)x(j)}\}]$ を，4.1 節で述べた手法を用いて，学習用データから求める．提案手法 1 と同様に図 29 に示すような HMM のネットワークを構成する．つまり Sil の HMM と Road の HMM をつなぎ合わせて，一つのモデルとする．ここで Road はドライアスファルト，ウェットアスファルト，圧雪，凍結，およびドライアスファルト以外，ウェットアスファルト以外，圧雪以外，凍結以外の HMM のいずれかに対応する．4 ステップ目でそれぞれのモデルの尤度の近似値を Viterbi アルゴリズムによって算出し，以下に示すような比較を行い，路面状態の判別を

行う．

- ・ $\hat{P}(O|M_{DRY}) > \hat{P}(O|M_{notDRY}) \Rightarrow \text{DRYと判別}$
- ・ $\hat{P}(O|M_{WET}) > \hat{P}(O|M_{notWET}) \Rightarrow \text{WETと判別}$
- ・ $\hat{P}(O|M_{SNOW}) > \hat{P}(O|M_{notSNOW}) \Rightarrow \text{SNOWと判別}$
- ・ $\hat{P}(O|M_{ICE}) > \hat{P}(O|M_{notICE}) \Rightarrow \text{ICEと判別}$

ただし， $\hat{P}(O|M_{DRY})$ ， $\hat{P}(O|M_{WET})$ ， $\hat{P}(O|M_{SNOW})$ ， $\hat{P}(O|M_{ICE})$ はそれぞれドライアスファルト，ウェットアスファルト，圧雪，凍結に対応する HMM の尤度の近似値， $\hat{P}(O|M_{notDRY})$ ， $\hat{P}(O|M_{notWET})$ ， $\hat{P}(O|M_{notSNOW})$ ， $\hat{P}(O|M_{notICE})$ はそれぞれドライアスファルト以外，ウェットアスファルト以外，圧雪以外，凍結以外に対応する HMM の尤度の近似値である．複数の路面状態に判別された場合は，当該路面に対応する HMM の尤度の近似値 $\hat{P}(O|M_{ROAD})$ を比較し，最も高い値に対応する路面状態に判別する．または全ての路面状態に対応する HMM の尤度が当該路面状態以外の HMM より値が小さい場合には， $\hat{P}(O|M_{DRY})$ ， $\hat{P}(O|M_{WET})$ ， $\hat{P}(O|M_{SNOW})$ ， $\hat{P}(O|M_{ICE})$ を比較して最も尤度が高い路面状態に判別するようにした．

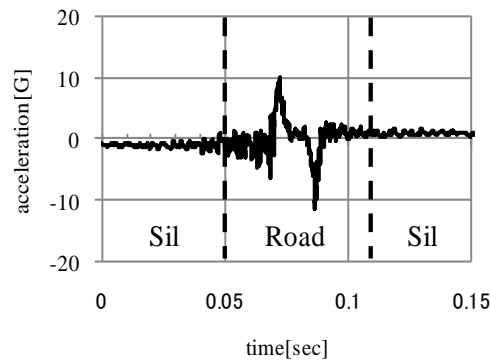


図 27 正解ラベル付けの例

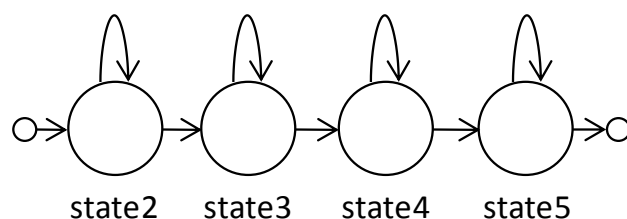


図 28 6 状態 left-to-right HMM の例

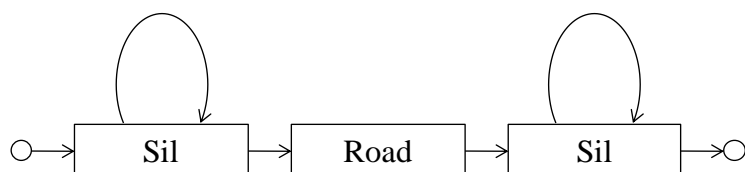


図 29 HMM のネットワーク

4.3 実験

4.3.1 実験方法

本研究の目的は，第 2 章で述べたように，タイヤ振動波形変化から潜在的に危険な路面状態を判別可能で，且つタイヤサイズ変更に対するロバスト性が高いシステムを構築することである．この目的に照らし，以下の 2 点を前提条件として実験を行った．

1. 路面状態はドライアスファルト，ウェットアスファルト，圧雪，凍結の 4 種に判別する
2. トレッドパターン（溝のデザイン）が同一でサイズが異なる 4 種のタイヤを用意し，その中から学習用データとテスト用データを選択する

本研究に用いたデータの取得条件を表 3 及び表 4 に示す．タイヤはすべて（株）ブリヂストン製スタッドレスタイヤ **BLIZZAK Revo2** を用いた．試験車の運転はすべて筆者が行い，試験補助者 1 名が助手席に同乗した．ドライアスファルト及びウェットアスファルトのデータは（株）ブリヂストンブルーピンググラウンドで取得した．ドライアスファルトは公道で一般的に用いられる平滑な舗装が均一に続く路面であり，ウェットアスファルトは水膜の厚さが約 1mm になるよう管理された平滑な舗装が均一に続く路面である．圧雪及び凍結のデータは（株）ブリ

デストン北海道ブルーミンググラウンドで取得した。圧雪は人工的に雪を踏み固めた路面である。気温や降雪の有無など天候に影響を受け、タイヤ種毎に若干の差異はあるが、テストコース内で管理されたほぼ均一な状態である。凍結は厚さ約 10mm の氷盤である。気温など天候に影響を受け、タイヤ種毎に若干の差異はあるが、テストコース内で管理されたほぼ均一な状態である。計測輪は左前輪とし、タイヤ回転方向を計測方向として、加速度センサをタイヤ内面の幅方向中心位置に取り付け、センサからの出力を A-D コンバータを介しサンプリングレート 10kHz で車内に設置した PC に収録した。なお、タイヤから車内への配線は、静止体から回転体に対して電気信号を伝達することのできるスリップリングを介し、有線方式で行った。タイヤ振動は各条件において連続的に収録されるが、本研究では路面状態に対応する情報が含まれる接地面近傍の波形を予め切り出して用意した。各条件における切り出した接地面近傍の波形の数を表 5 に示す。各路面条件でデータ数が異なるのは、コース距離の制約によるものである。

Index	Tire size	The model of a car
Tire A	165/70R14	TOYOTA Vitz
Tire B	195/65R15	TOYOTA MARK II
Tire C	195/60R15	TOYOTA CAROLLA FIELDER
Tire D	185/70R14	TOYOTA CAROLLA FIELDER

表 3 タイヤサイズと試験車両

Road condition	Velocity
Dry asphalt	30kph～90kph every 10kph
Wet asphalt	30kph～90kph every 10kph
Compacted snow	30kph～80kph every 10kph
Ice	30kph and 40kph

表 4 路面状態とデータ取得速度

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	204	217	221	212	182	152	175
wet	66	72	69	67	61	67	50
snow	180	221	234	222	188	165	-
ice	73	71	-	-	-	-	-

(a) タイヤ A

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	215	213	209	209	199	188	162
wet	75	72	69	75	68	67	74
snow	154	253	242	220	194	207	-
ice	62	60	-	-	-	-	-

(b) タイヤ B

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	200	211	209	200	198	177	137
wet	71	72	69	75	68	67	62
snow	158	250	252	175	166	122	-
ice	66	66	-	-	-	-	-

(c) タイヤ C

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	183	219	202	200	195	188	162
wet	75	72	69	67	68	67	69
snow	121	183	128	193	364	277	-
ice	66	66	-	-	-	-	-

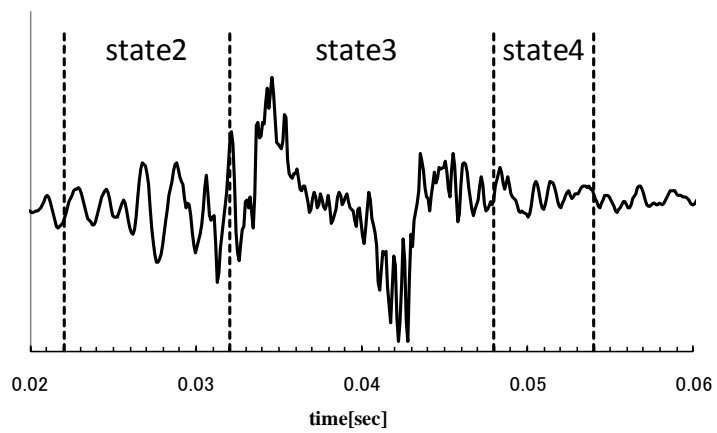
(d) タイヤ D

表 5 各条件のデータ数

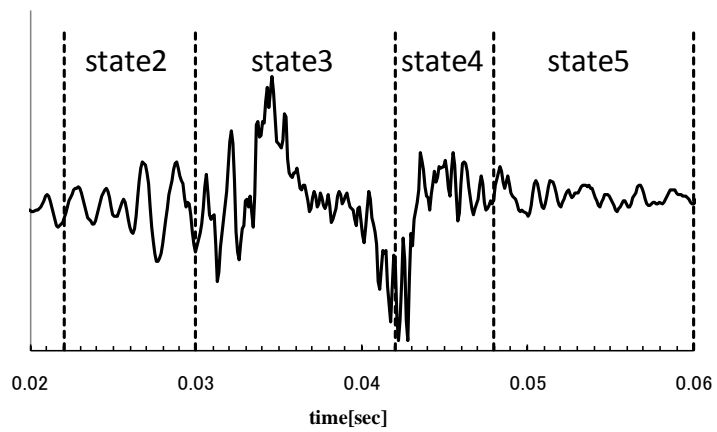
4.3.2 HMM による状態推定

構成した HMM がタイヤ接地状態を反映した振動波形の特徴をどのようにモデル化しているかを確認するため、状態系列を調べた。GMM の混合数は 1 とした。図 30 はタイヤ A がドライアスファルトを 60kph で走行した時のタイヤ 1 回転分の波形を代表例として、Viterbi アルゴリズムで推定した状態系列を波形上に示したものである。図中の状態番号はすべてドライアスファルトに対応する HMM の状態を示すものである。モデルは 4.2 節で述べたように、Sil と Road の HMM を組み合わせたネットワークを構成したものとし、モデルのパラメータはタイヤ B, C, D の全てのデータを用いて、Baum-Welch アルゴリズムによって推定した。なお、本検討では路面状態に関する情報が含まれる接地面近傍波形のモデルの妥当性が重要であるため、図 30 に示したドライアスファルトに対応する HMM の各開始状態の前と終了状態の後にある Sil の状態系列については省略した。

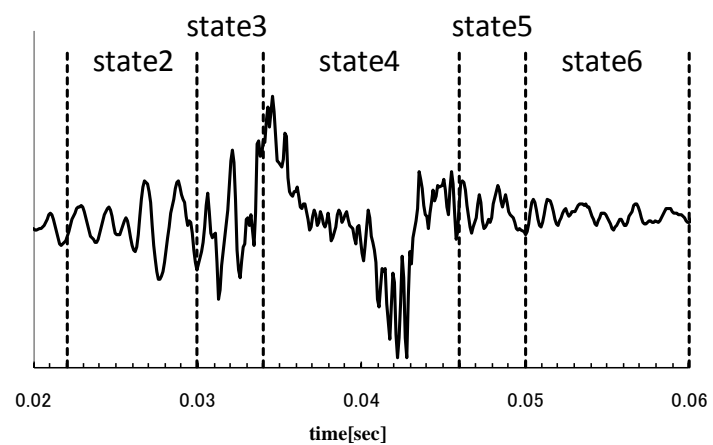
図 30 (a)の 5 状態モデルでは、接地面付近(state3 に対応)とそれ以外に状態を分けているのに対し、図 30 (b)の 6 状態モデルでは、蹴り出し後の波形に 1 つの状態を割り当てており(state4 に対応)、第 3 章で述べた路面蹴り出し後のトレッドゴムブロック固有振動の特徴を反映していると考えられる。さらに図 30 (c)の 7 状態のモデルでは、踏み込み位置付近で状態が分かれており(state3 に対応)、状態数が増えるのに伴い、より詳細にタイヤ振動の構造を捉えられるようになっている。従来法 [16] [17] [18]では波形の特徴が異なる領域を経験的に決定していたが、本検討によりその経験的知識がデータの構造からも示された。



(a) 状態数 5



(b) 状態数 6



(c) 状態数 7

図 30 Viterbi アルゴリズムで推定した状態系列

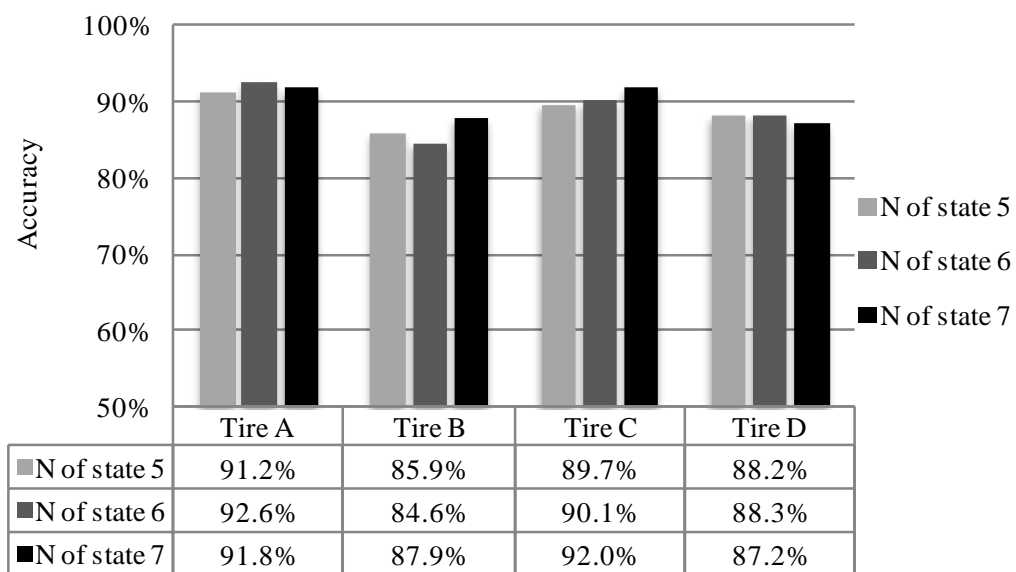
4.3.3 HMM に基づく判別手法の精度

表 3 に示すタイヤ 4 種の内 3 種のタイヤの全データを学習用，残りの 1 種のタイヤの全データをテスト用とし，GMM の混合数 1 のモデルについて認識テストを行った．学習用データには表 5 に示す全ての速度域が含まれるため，モデルパラメータは系列長が異なる全ての速度域のデータの平均となる．図 31 図 32 は HMM の状態数を開始，終了状態を含めて 5, 6, 7 状態とした時それぞれについての正答率を，テスト用に使用したタイヤごとに表したものである．ここで言う正答率とは，タイヤが 1 回転するごとに出力される接地面近傍の波形から，上記の方法で路面状態を判別し，それを一つのデータ点として判別された結果と正解とを比較し，正答数をデータ総数で除したものである．

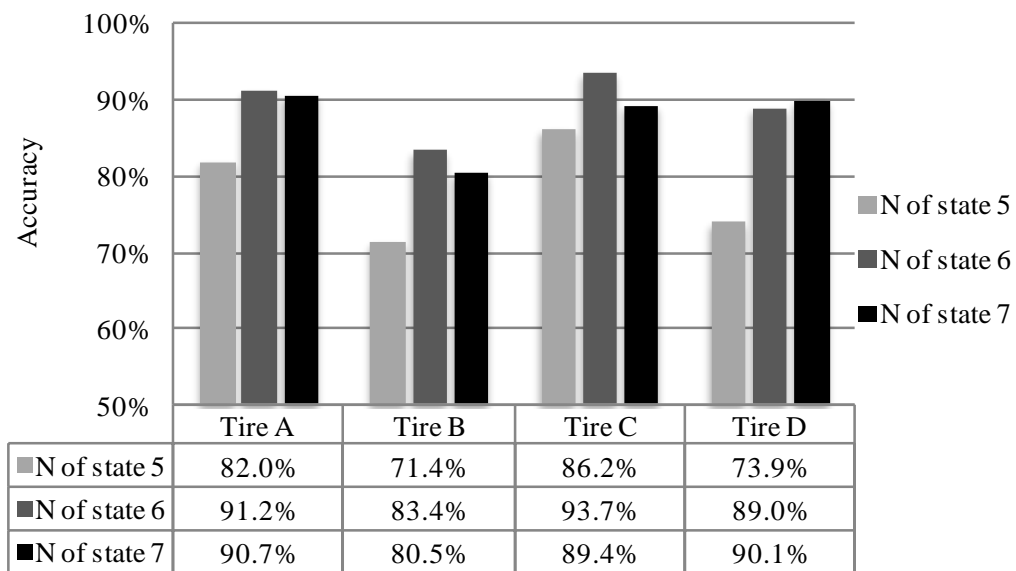
図 31 (a)に示すように，特徴量を LPC ケプストラム係数とした時の提案手法 1 の正答率は，状態数 6 のモデルでは 84.6%~92.6%であり，状態数 7 のモデルでは 87.2%~92.0%であった．同様に提案手法 2 の正答率は図 32 (a)に示すように状態数 6 のモデルでは 84.5%~92.6%であり，状態数 7 のモデルでは 87.8%~92.4%であった．一方特徴量をバンドパスフィルタ透過波のパワー値の平均とした時の提案手法 1 の正答率は，図 31 (b)に示すように，状態数 6 のモデルでは 83.4%~93.7%であり，状態数 7 のモデルでは 80.5%~90.7%であった．また提案手法 2 の正答率は図 32 (b)に示すように状態数 6 のモデルでは 83.4%~93.7%であり，状態数 7 のモデルでは 80.5%~90.7%であった．特徴量の比較では，ほとんどの条件で LPC ケプストラム係数を採用したモデルのほうが正答率が高かった．一方，本研究で提案した判別手法の違いによる正答率の大きな差は見られなかった．また HMM の状態数の比較では，多数の条件において 5 状態のモデルよりも 6 または 7 状態のモデルのほうが高精度であった．

より詳細に試験結果を分析するため，走行条件毎の正答率を調べた．表 6 は特徴量を LPC ケプストラム係数とした時の HMM 状態数 7 のモデルにおける，提案手法 1 の正答率を速度・路面状態毎に示したものである．TireA と TireC は全体的に高い正答率を示しているが，TireB および TireD の低速域の圧雪は正答率が低い．この傾向は表 7 に示す提案手法 2 の場合でも同様である．一方，表 8 は特徴量をバンドパスフィルタ透過波のパワー値の平均とした時の HMM 状態数 7 のモデルにおける，提案手法 1 の正答率を速度・路面状態毎に示したものである．TireD

における圧雪の 40km/h, 50km/h は特徴量を LPC ケプストラム係数とした時に比べて正答率が大きく上昇しているが, 逆に TireA における圧雪の 30km/h や TireB における 40~60km/h のウェットアスファルト, TireC における 50~70km/h のウェットアスファルトや 30km/h の圧雪は精度が低下している. この傾向は表 9 に示す提案手法 2 の場合でも同様である.

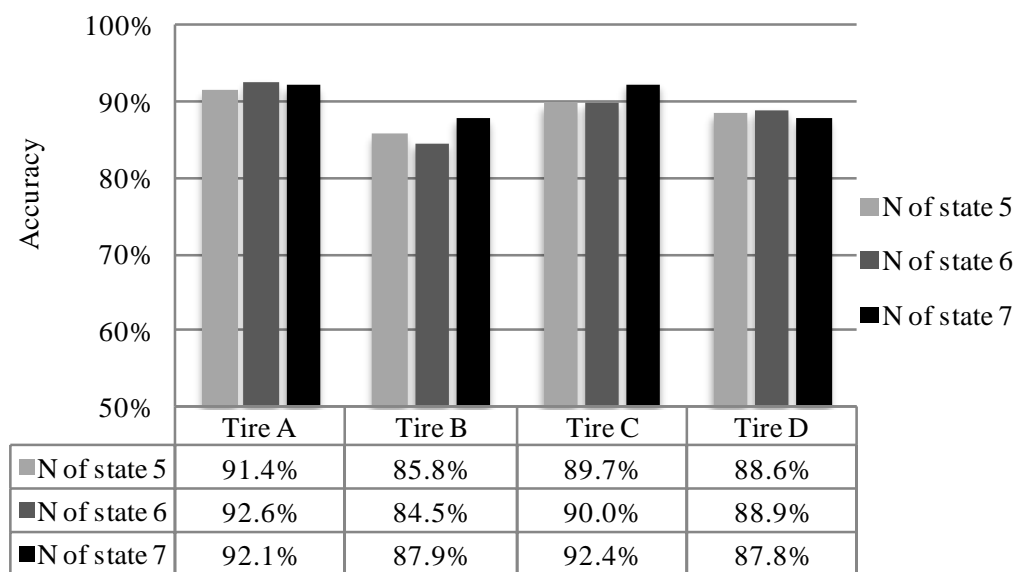


(a) 特徴量：LPC ケプストラム

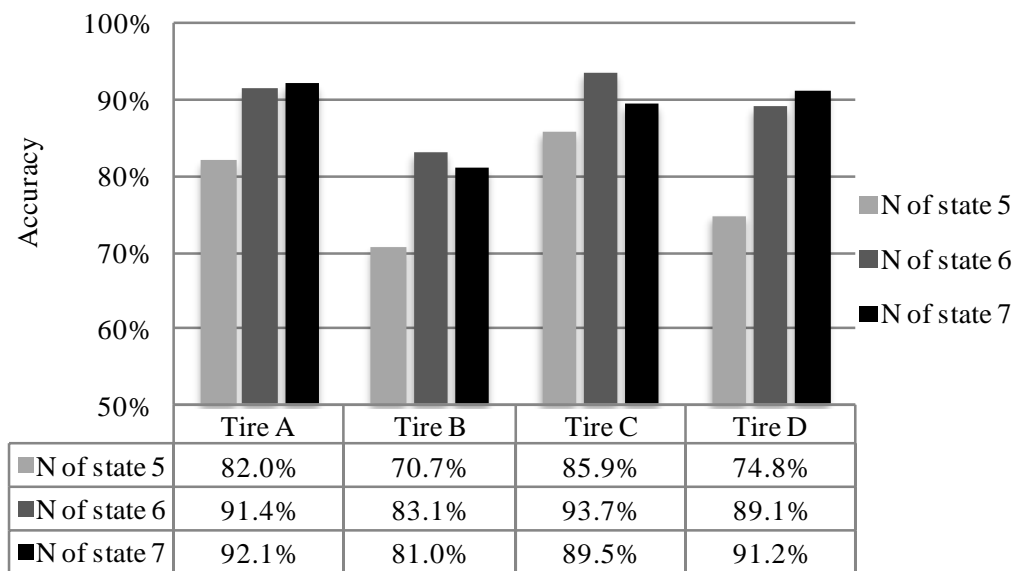


(b) 特徴量：バンドパスフィルタ

図 31 提案手法 1 の認識テスト結果



(a) 特徴量：LPC ケプストラム



(b) 特徴量：バンドパスフィルタ

図 32 提案手法 2 の認識テスト結果

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	75.0%	89.9%	98.6%	99.5%	99.5%	98.7%	97.7%
wet	100.0%	95.8%	97.1%	97.0%	93.4%	83.6%	96.0%
snow	77.2%	83.3%	91.5%	95.5%	93.1%	89.1%	-
ice	98.6%	83.1%	-	-	-	-	-

(a) TireA

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	97.2%	100.0%	99.5%	99.0%	99.0%	99.5%	100.0%
wet	100.0%	100.0%	92.8%	98.7%	95.6%	94.0%	97.3%
snow	7.8%	48.2%	90.1%	99.1%	100.0%	89.4%	-
ice	48.4%	68.9%	-	-	-	-	-

(b) TireB

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	81.0%	94.3%	96.2%	99.5%	98.0%	99.4%	99.3%
wet	100.0%	95.8%	82.6%	85.3%	73.5%	76.1%	82.3%
snow	81.0%	84.0%	89.3%	98.9%	97.6%	97.5%	-
ice	97.0%	98.5%	-	-	-	-	-

(c) TireC

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	65.6%	92.7%	98.5%	99.5%	99.5%	98.4%	98.8%
wet	100.0%	100.0%	98.6%	100.0%	100.0%	100.0%	88.4%
snow	67.8%	67.8%	64.1%	88.1%	83.2%	68.6%	-
ice	100.0%	100.0%	-	-	-	-	-

(d) TireD

表 6 速度・路面状態毎の精度

特徴量：LPC ケプストラム係数，判別手法：1，HMM 状態数：7

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	77.9%	90.3%	99.5%	99.5%	99.5%	98.7%	97.1%
wet	100.0%	95.8%	97.1%	97.0%	91.8%	83.6%	96.0%
snow	77.2%	83.3%	92.3%	95.5%	93.6%	89.1%	-
ice	98.6%	83.1%	-	-	-	-	-

(a) TireA

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	97.2%	100.0%	99.0%	99.0%	99.0%	99.5%	100.0%
wet	100.0%	100.0%	92.8%	98.7%	94.1%	92.5%	97.3%
snow	7.8%	48.6%	90.5%	99.1%	100.0%	89.4%	-
ice	50.0%	68.9%	-	-	-	-	-

(b) TireB

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	84.0%	94.3%	96.7%	99.5%	98.0%	99.4%	99.3%
wet	100.0%	95.8%	78.3%	82.7%	73.5%	73.1%	82.3%
snow	82.9%	86.4%	90.1%	98.9%	97.6%	97.5%	-
ice	98.5%	98.5%	-	-	-	-	-

(c) TireC

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	69.9%	92.7%	98.5%	99.5%	100.0%	98.4%	98.8%
wet	100.0%	98.6%	98.6%	100.0%	100.0%	98.5%	88.4%
snow	70.2%	67.8%	68.8%	88.1%	84.1%	69.0%	-
ice	100.0%	100.0%	-	-	-	-	-

(d) TireD

表 7 速度・路面状態毎の精度

特徴量：LPC ケプストラム係数，判別手法：2，HMM 状態数：7

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	97.7%	100.0%	100.0%	100.0%	86.9%
wet	98.5%	98.6%	68.1%	77.6%	80.3%	85.1%	100.0%
snow	39.4%	87.3%	96.2%	99.1%	84.0%	84.8%	-
ice	100.0%	97.2%	-	-	-	-	-

(a) TireA

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	99.5%	78.0%	72.2%	81.9%	89.4%	76.5%
wet	81.3%	26.4%	4.3%	21.3%	94.1%	100.0%	97.3%
snow	55.2%	58.9%	92.1%	100.0%	100.0%	95.0%	-
ice	100.0%	30.0%	-	-	-	-	-

(b) TireB

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
wet	100.0%	98.6%	4.3%	30.7%	61.8%	95.5%	96.8%
snow	21.5%	95.6%	100.0%	100.0%	97.6%	95.1%	-
ice	100.0%	53.0%	-	-	-	-	-

(c) TireC

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	99.5%	99.0%	100.0%	100.0%	100.0%	98.8%
wet	84.0%	100.0%	84.1%	89.6%	97.1%	97.0%	92.8%
snow	15.0%	92.3%	95.3%	99.5%	88.5%	59.9%	-
ice	98.5%	100.0%	-	-	-	-	-

(d) TireD

表 8 速度・路面状態毎の精度

特微量：バンドパスフィルタ，判別手法：1，HMM 状態数：7

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	99.5%	94.1%	100.0%	100.0%	100.0%	86.3%
wet	95.5%	97.2%	95.7%	98.5%	95.1%	91.0%	100.0%
snow	38.3%	83.7%	94.4%	99.1%	91.0%	92.7%	-
ice	100.0%	95.8%	-	-	-	-	-

(a) TireA

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	99.5%	78.5%	72.2%	81.9%	89.9%	72.2%
wet	81.3%	26.4%	4.3%	22.7%	94.1%	100.0%	98.6%
snow	56.5%	63.6%	95.0%	100.0%	100.0%	96.5%	-
ice	100.0%	30.0%	-	-	-	-	-

(b) TireB

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
wet	100.0%	100.0%	4.3%	32.0%	61.8%	95.5%	96.8%
snow	21.5%	96.0%	100.0%	100.0%	97.6%	95.9%	-
ice	100.0%	51.5%	-	-	-	-	-

(c) TireC

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	99.5%	100.0%	98.5%	100.0%	98.4%	93.8%
wet	66.7%	100.0%	97.1%	98.5%	100.0%	100.0%	98.6%
snow	14.2%	95.1%	87.5%	96.9%	93.1%	71.8%	-
ice	98.5%	100.0%	-	-	-	-	-

(d) TireD

表 9 速度・路面状態毎の精度

特微量：バンドパスフィルタ，判別手法：2，HMM 状態数：7

4.3.4 サイズロバスト性の検証

次に 1 種のタイヤのデータで学習したモデルが，他のタイヤ種のデータの判別にも適用できるかを調べた．同様に GMM の混合数 1 とした．学習用データとテスト用データを以下のように設定した．表 1 に示すタイヤ 4 種の内 1 種を選び，路面状態ごとに，すべての速度域が含まれるように，総データ数の 3 分の 2 を抜粋する．これをまとめて学習用データとする．学習用データには表 5 に示す全ての速度域が含まれるため，モデルパラメータは系列長が異なる全ての速度域のデータの平均となる．上記の学習用データに採用されなかった残りの 3 分の 1 のデータと，他のタイヤ 3 種のすべてのデータをテスト用とする．これを 4 度繰り返して，すべてのタイヤ種が学習データとなるように認識テストを行った．図 33～図 36 はそれぞれ，

図 33: タイヤ A のデータを学習用に使用したとき

図 34: タイヤ B のデータを学習用に使用したとき

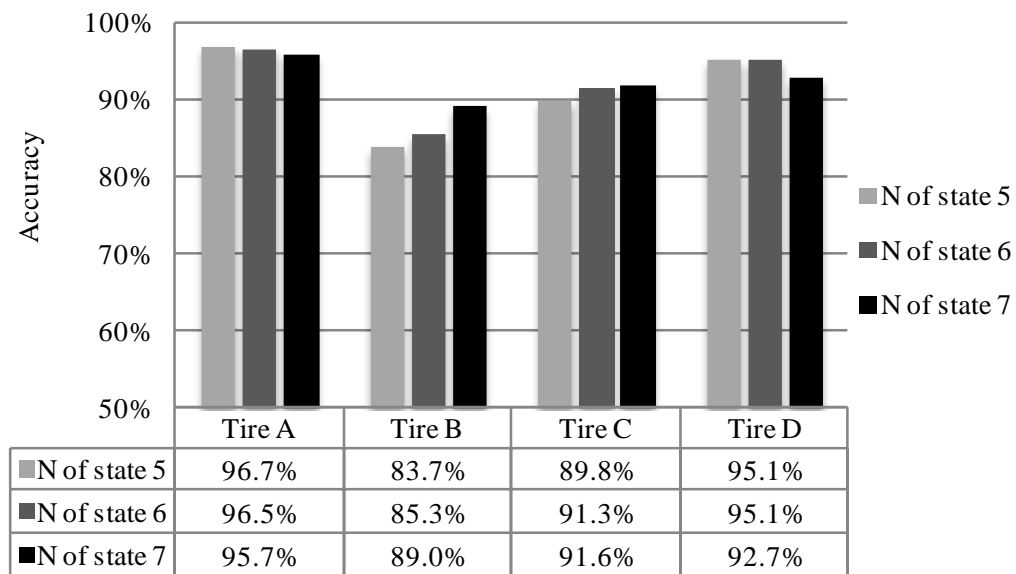
図 35: タイヤ C のデータを学習用に使用したとき

図 36: タイヤ D のデータを学習用に使用したとき

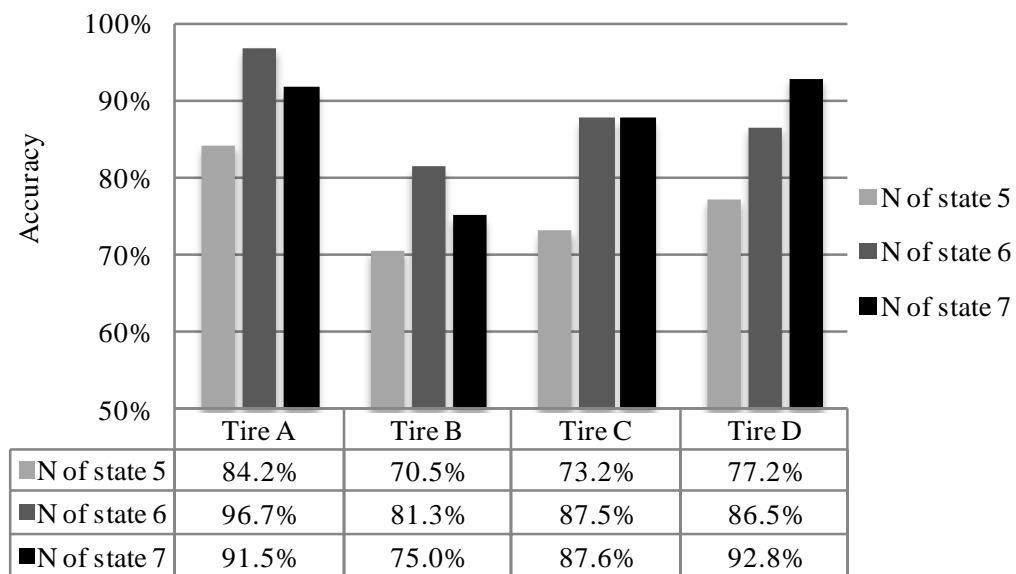
の正答率を示したものであり，(a) は特徴量に LPC ケプストラム係数を用いた時，(b) は特徴量にバンドパスフィルタ透過波のパワー値の平均値を用いた時の正答率である．判別方法は 4.2 節で説明した提案手法 1 を用いた．

図 33(a) に示すように Tire A のデータを学習用に使用したとき，状態数 7 のモデルでは正答率 89% 以上であり，1 つのタイヤサイズのデータのみで他サイズのタイヤでも高精度に路面状態の判別ができる可能性が示された．しかし，図 33～図 36 の(a) に示すように，Tire B のデータで学習した時の正答率，及び他のタイヤのデータで学習した時の Tire B の正答率が他の条件よりも若干低くなっており，このことは Tire B の振動波形の特徴が他のタイヤとは異なっている可能性を示唆している．上述の傾向は図 33～図 36 の(b) に示す特徴量をバンドパスフィルタ透過波のパワー値の平均とした場合も同様である．特徴量の比較では，多数の条件で LPC ケプストラム係数を採用したモデルのほうが高精度だった．また HMM の状態数の比較では，多数の条件において 5 状態のモデルよりも 6 または 7 状態のモデルのほうが高精度であった．

より詳細に試験結果を分析するため、特徴量を LPC ケプストラム係数とした時の走行条件毎の正答率を調べた。例えば、TireA で学習した時の TireB の正答率は図 33(a)で示したように 89%であり、表 10 (b)で示したように多数の条件で 80%以上の高精度で判別できている一方、30km/h の圧雪や 30km/h, 40km/h の凍結など一部正答率が低い条件があった。同様に圧雪と凍結の低速域で正答率が 50%未満の条件は他のタイヤで学習した場合でも見られ、モデルの適応性に速度依存性や路面状態に対する依存性があることが示唆された。

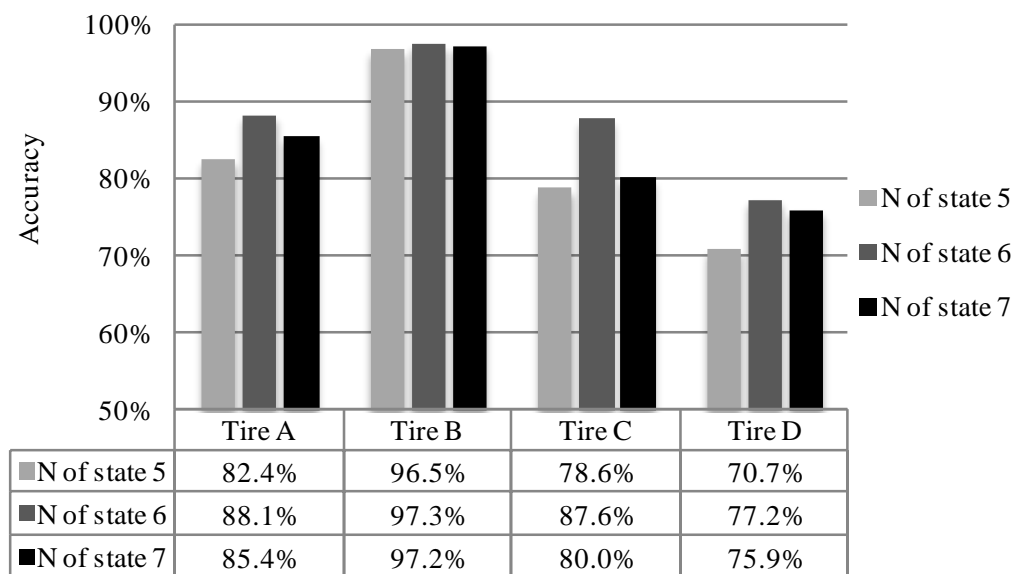


(a) 特徴量：LPC ケプストラム係数

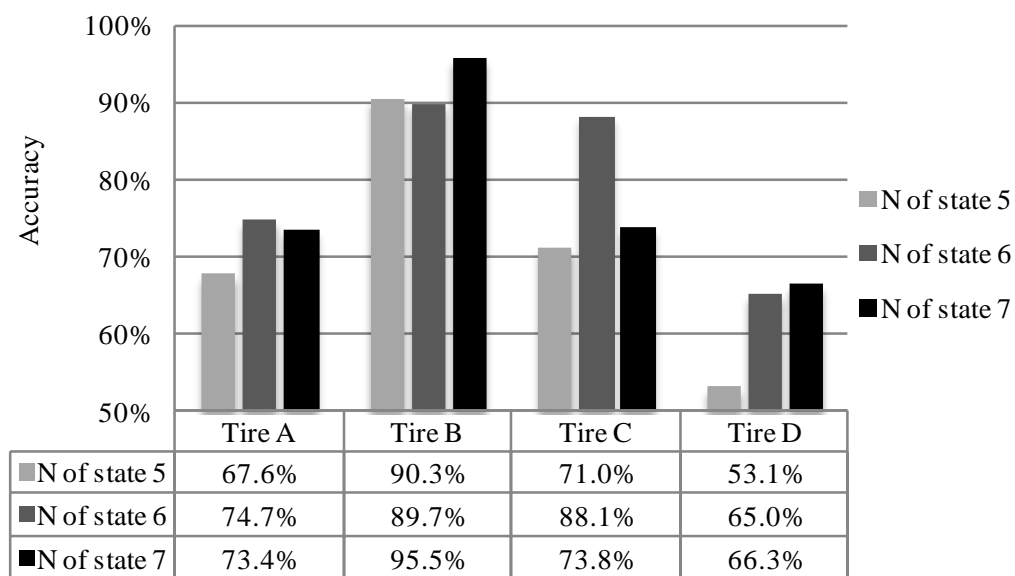


(b) 特徴量：バンドパスフィルタ透過波のパワー値の平均値

図 33 タイヤ A のデータを学習用に使用したときの精度

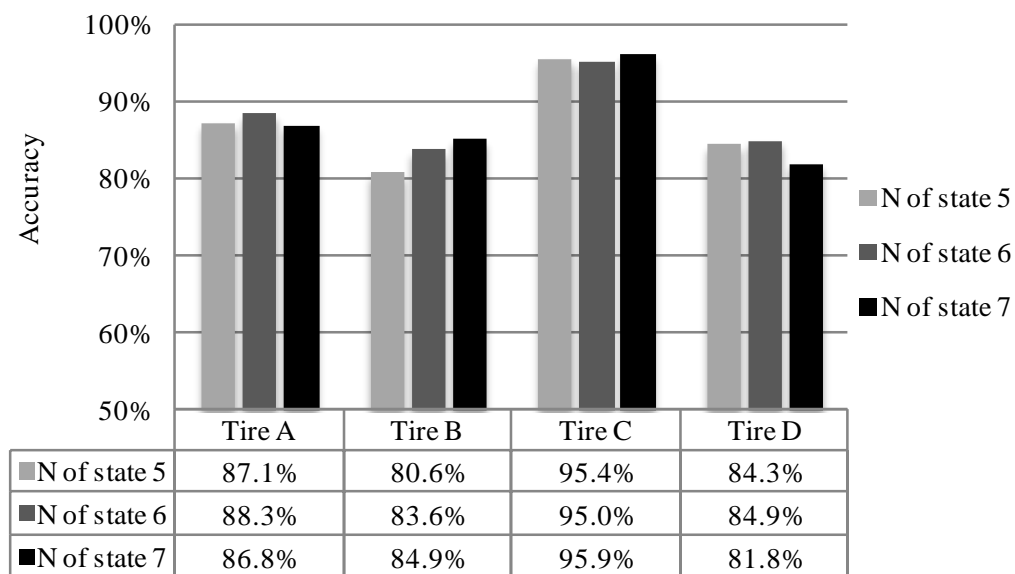


(a) 特徴量：LPC ケプストラム係数

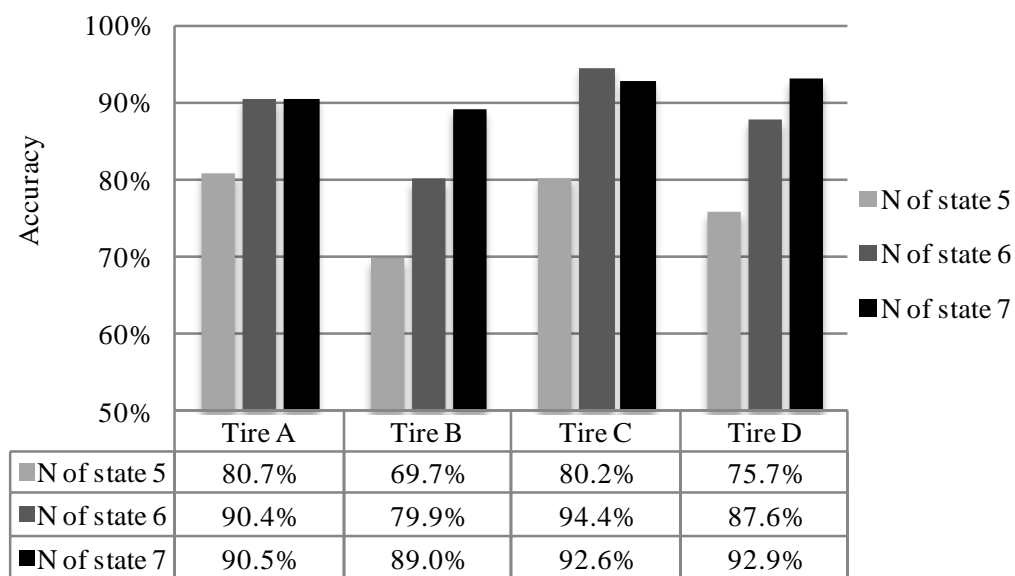


(b) 特徴量：バンドパスフィルタ透過波のパワー値の平均値

図 34 タイヤ B のデータを学習用に使用したときの精度

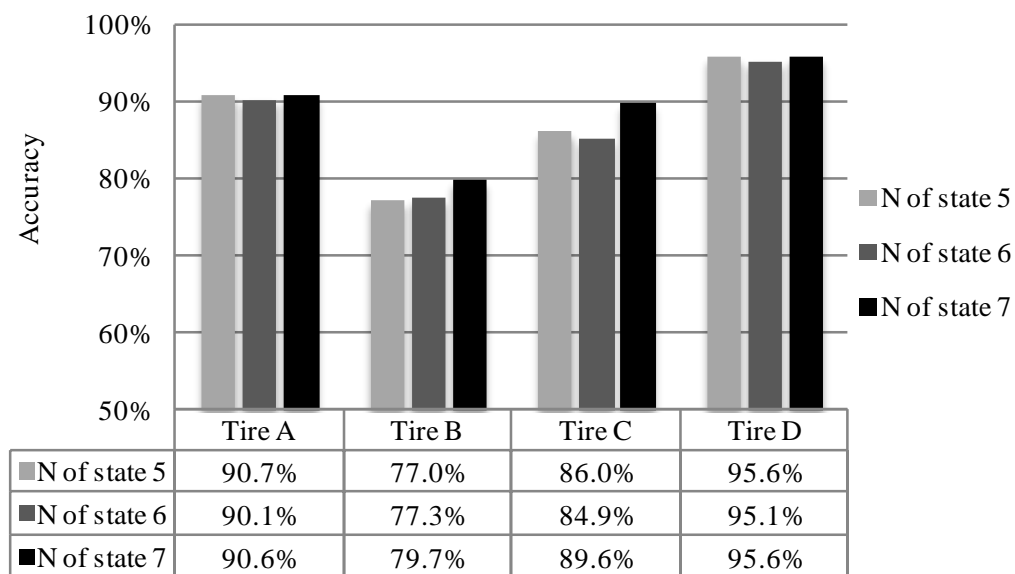


(a) 特徴量：LPC ケプストラム係数

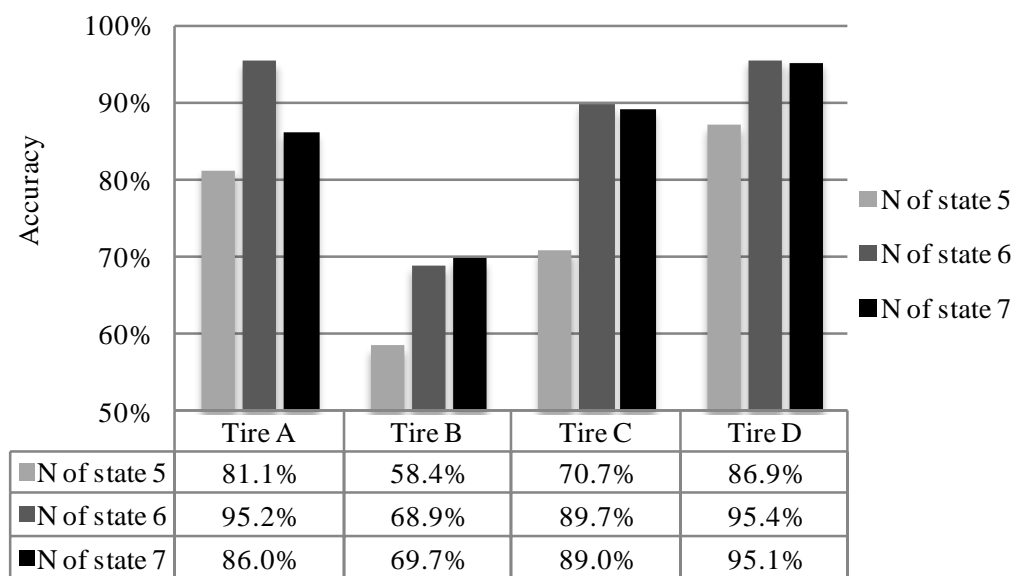


(b) 特徴量：バンドパスフィルタ透過波のパワー値の平均値

図 35 タイヤ C のデータを学習用に使用したときの精度



(a) 特徴量：LPC ケプストラム係数



(b) 特徴量：バンドパスフィルタ透過波のパワー値の平均値

図 36 タイヤ D のデータを学習用に使用したときの精度

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	97.0	98.6	98.6	98.6	100.0	95.9	89.7
wet	93.8	90.9	90.0	95.5	100.0	95.8	95.5
snow	76.7	94.6	96.2	98.7	98.4	96.4	-
ice	100.0	100.0	-	-	-	-	-

(a) TireA

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	97.7	100.0	99.5	99.5	97.5	97.3	98.8
wet	90.5	100.0	98.6	85.8	97.3	77.9	85.1
snow	27.9	76.3	96.3	99.6	100.0	91.3	-
ice	0.0	36.7	-	-	-	-	-

(b) TireB

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	94.0	97.6	98.1	98.5	98.5	98.9	99.3
wet	98.6	94.4	68.1	60.0	58.8	53.7	64.5
snow	95.6	98.8	99.2	98.9	100.0	98.4	-
ice	65.2	22.7	-	-	-	-	-

(c) TireC

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	84.2	94.5	98.5	99.0	98.5	97.9	97.5
wet	100.0	98.6	97.1	92.5	77.9	76.1	89.9
snow	83.5	92.4	86.7	96.9	94.2	87.7	-
ice	75.8	93.9	-	-	-	-	-

(d) TireD

表 10 TireA を学習データとした時の速度・路面状態毎の精度

特徴量：LPC ケプストラム 状態数 7

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	90.2	98.2	100.0	100.00	99.5	99.3	98.9
wet	96.0	85.1	90.2	86.6	94.2	97.2	100.0
snow	87.2	83.7	73.5	71.2	69.2	58.8	-
ice	71.	1.4	-	-	-	-	-

(a) TireA

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	97.2	100.0	100.0	100.0	100.0	100.0	100.0
wet	100.0	100.0	82.6	100.0	91.3	86.4	100.0
snow	100.0	100.0	100.0	97.3	96.9	78.3	-
ice	95.2	100.0	-	-	-	-	-

(b) TireB

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	92.0	98.1	100.0	100.0	100.0	100.0	100.0
wet	98.5	97.2	81.2	70.7	69.2	61.2	75.8
snow	50.0	62.4	56.4	78.9	60.8	70.5	-
ice	47.0	40.9	-	-	-	-	-

(c) TireC

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	86.9	99.1	100.0	100.0	100.0	98.9	100.0
wet	100.0	98.6	94.2	100.0	95.6	89.6	97.1
snow	66.9	54.6	28.1	53.9	48.6	33.2	-
ice	100.0	10.6	-	-	-	-	-

(d) TireD

表 11 TireB を学習データとした時の速度・路面状態毎の精度

特徴量：LPC ケプストラム 状態数 7

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	77.9	94.0	99.1	99.5	97.3	95.4	87.4
wet	92.0	83.6	82.0	100.0	100.0	97.2	100.0
snow	61.1	89.1	80.3	92.3	78.7	76.4	-
ice	94.5	21.1	-	-	-	-	-

(a) TireA

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	88.8	99.1	99.5	100.0	100.0	100.0	100.0
wet	100.0	100.0	98.6	100.0	98.5	97.0	96.0
snow	13.6	48.2	92.2	93.2	95.9	63.8	-
ice	54.8	11.7	-	-	-	-	-

(b) TireB

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	96.7	100.0	100.0	100.0	100.0	100.0	100.0
wet	100.0	100.0	87.0	96.0	95.7	72.7	90.5
snow	88.5	100.0	94.1	98.3	87.3	80.5	-
ice	100.0	100.0	-	-	-	-	-

(c) TireC

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	53.0	93.2	99.5	99.0	98.0	94.2	96.3
wet	100.0	100.0	100.0	100.0	100.0	97.0	91.3
snow	42.1	76.0	54.7	86.0	75.3	59.9	-
ice	98.5	15.2	-	-	-	-	-

(d) TireD

表 12 TireC を学習データとした時の速度・路面状態毎の精度

特徴量：LPC ケプストラム 状態数 7

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	92.7	99.5	100.0	99.1	98.9	98.7	91.4
wet	94.0	86.6	95.1	97.0	98.6	98.6	98.5
snow	18.3	87.8	97.0	99.6	100.0	98.2	-
ice	91.8	29.6	-	-	-	-	-

(a) TireA

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0	100.0	97.6	97.6	90.5	92.6	97.5
wet	100.0	100.0	95.7	85.3	75.0	55.2	85.1
snow	1.3	17.0	65.2	98.2	99.5	90.8	-
ice	32.3	36.7	-	-	-	-	-

(b) TireB

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	98.0	99.1	97.6	98.0	96.5	97.2	98.5
wet	100.0	95.8	73.9	89.3	61.8	59.7	85.5
snow	48.7	78.0	94.4	98.9	100.0	100.0	-
ice	86.4	39.4	-	-	-	-	-

(c) TireC

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	95.1	100.0	97.0	100.0	100.0	100.0	100.0
wet	100.0	100.0	95.7	100.0	87.0	81.8	100.0
snow	35.0	96.7	100.0	100.0	100.0	93.5	-
ice	100.0	100.0	-	-	-	-	-

(d) TireD

表 13 TireD を学習データとした時の速度・路面状態毎の精度

特徴量：LPC ケプストラム 状態数 7

4.3.5 出力確率関数として用いた GMM の混合数の影響

前節までは、HMM の出力確率に用いた GMM の混合数を 1 としてモデルを構築し認識テストを行ってきたが、本節では混合数を変化させ、その影響を調べた結果を示す。表 3 に示すタイヤ 4 種の内 3 種のタイヤの全データを学習用、残りの 1 種のタイヤの全データをテスト用とし、認識テストを行った。図 37 は HMM の状態数を 7、特徴量を LPC ケプストラム係数とし、判別方法を 4.2 節で説明した手法 1 とした時の正答率を、テスト用に使用したタイヤごとに示したものである。図 37 が示す通り、Tire B を除く 3 種のタイヤでは GMM の混合数増大とともに、精度も上昇している。より詳細に試験結果を分析するため、走行条件毎の正答率を調べた。表 14 は HMM の状態数を 7、特徴量を LPC ケプストラム係数、GMM の混合数を 3 とした時の速度・路面状態毎の精度である。表 6 に示した GMM の混合数 1 の場合と比較して、Tire A の低速域でのドライアスファルトや Tire D の低速域の圧雪の精度は向上しているが、Tire B の凍結の精度は大きく低下している。

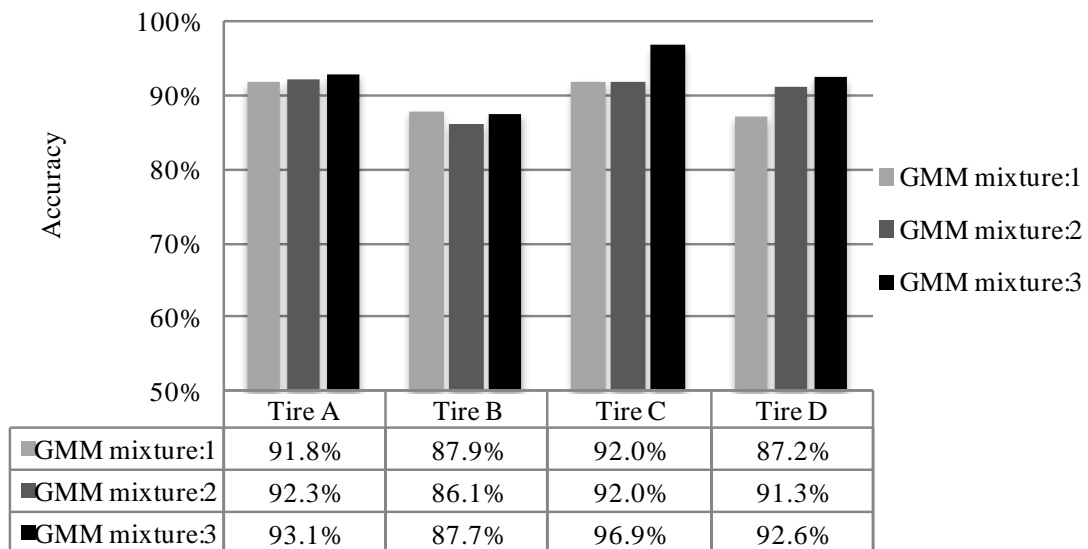


図 37 GMM の混合数の影響

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	95.6	98.6	100.0	99.1	97.8	98.0	78.9
wet	98.0	86.6	90.2	95.5	97.1	95.8	100.0
snow	67.2	87.8	97.9	99.6	95.7	86.1	-
ice	98.6	81.7	-	-	-	-	-

(a) TireA

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	97.7	100.0	99.0	98.1	95.5	93.6	95.1
wet	100.0	100.0	100.0	98.7	94.1	86.6	100.0
snow	26.0	60.1	94.2	99.6	100.0	95.7	-
ice	0.0	18.3	-	-	-	-	-

(b) TireB

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	98.0	99.1	99.0	100.0	97.9	100.0	97.8
wet	100.0	100.0	94.2	85.3	82.4	85.1	100.0
snow	89.9	96.0	97.6	99.4	99.4	98.3	-
ice	92.4	97.0	-	-	-	-	-

(c) TireC

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	96.7	99.5	100.0	100.0	100.0	97.9	98.8
wet	100.0	100.0	100.0	100.0	100.0	98.5	100.0
snow	85.1	78.7	75.0	95.3	87.1	72.2	-
ice	98.5	98.5	-	-	-	-	-

(d) TireD

表 14 GMM の混合数を 3 とした時の速度・路面状態毎の精度

次に 1 種のタイヤのデータで学習したモデルが、他のタイヤ種のデータの判別にも適用できるかを調べた。GMM の混合数は同様に 1, 2, 3 のいずれかとした。学習用データとテスト用データを以下のように設定した。表 3 に示すタイヤ 4 種の内 1 種を選び、路面状態ごとに、すべての速度域が含まれるように、総データ数の 3 分の 2 を抜粋する。これをまとめて学習用データとする。学習用データには表 5 に示す全ての速度域が含まれるため、モデルパラメータは系列長が異なる全ての速度域のデータの平均となる。上記の学習用データに採用されなかった残りの 3 分の 1 のデータと、他のタイヤ 3 種のすべてのデータをテスト用とする。これを 4 度繰り返して、すべてのタイヤ種が学習データとなるように認識テストを行った。図 38～図 41 はそれぞれ、

図 38: タイヤ A のデータを学習用に使用したとき

図 39: タイヤ B のデータを学習用に使用したとき

図 40: タイヤ C のデータを学習用に使用したとき

図 41: タイヤ D のデータを学習用に使用したとき

の正答率を示したものであり、特徴量に LPC ケプストラム係数を用いた。判別方法は 4.2 節で説明した提案手法 1 を用いた。ほとんどの条件で、GMM の混合数を 2 または 3 に増加させることによって精度が向上したが、Tire A で学習した時の Tire B の精度と、Tire D で学習した時の Tire B の精度は大きく低下した。

より詳細に試験結果を分析するために、走行条件毎の正答率を調べた。表 15 表 16, 表 17, 表 18 は、HMM の状態数を 7, 特徴量を LPC ケプストラム係数, GMM の混合数を 3 とした時の速度・路面状態毎の精度である。4.3.4 節で述べたように、GMM の混合数を 1 とした時、一部の条件で正答率が低く、モデルの適応性に速度依存性や路面状態に対する依存性があることが示唆された。混合数を増やすことにより、モデルの表現力を高め、そのような依存性を排除することを目指したが、結果としては精度の低い条件を改善することはできなかった。例えば表 10 と表 15 比較すると、Tire B の低速での凍結や Tire C の凍結は、むしろ精度が低下している。同様に表 11 と表 16, 表 12 と表 17, 表 13 と表 18 の比較でも、精度向上を狙った凍結路面の精度が低下していることがわかる。これは GMM の混合数を増やしたことでモデルパラメータ数が増大したために、過学習を引き起こしたと考えられる。特に表 5 に示すように、凍結路のデータ数は他に比べて少ないので、過学習に陥りやすかったと考えられる。

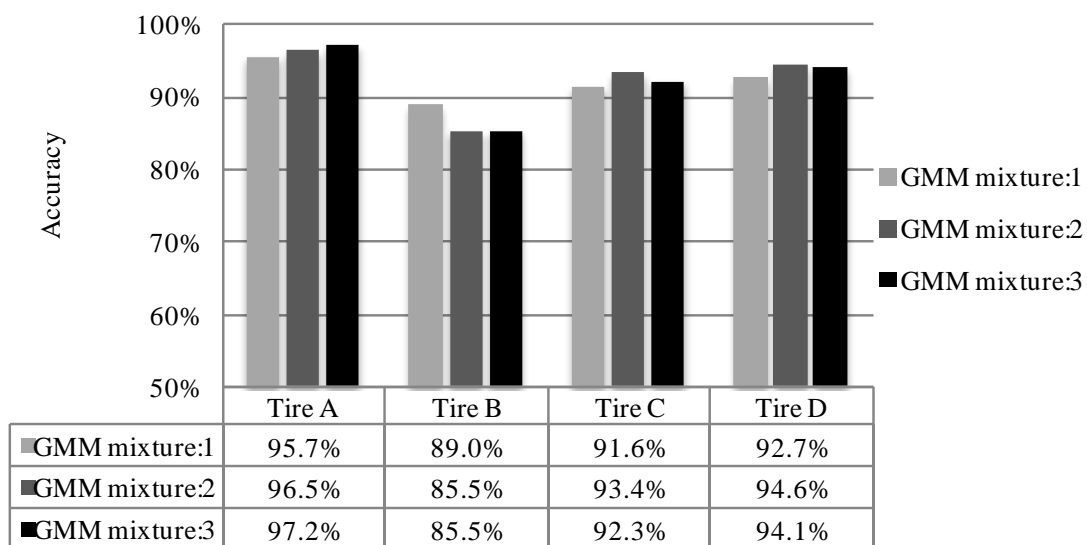


図 38 TireA のデータを学習用に使用したときの精度

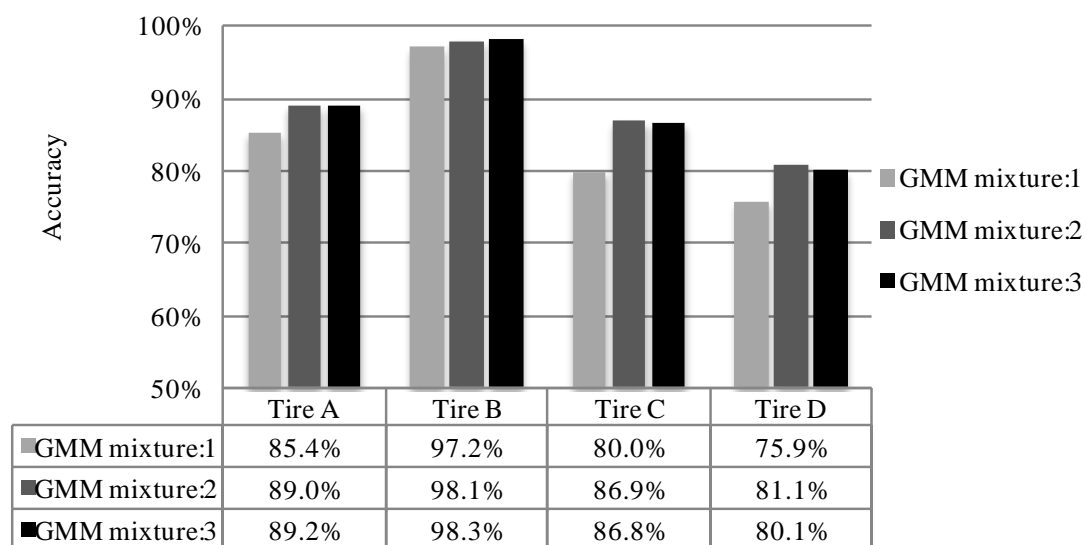


図 39 TireB のデータを学習用に使用したときの精度

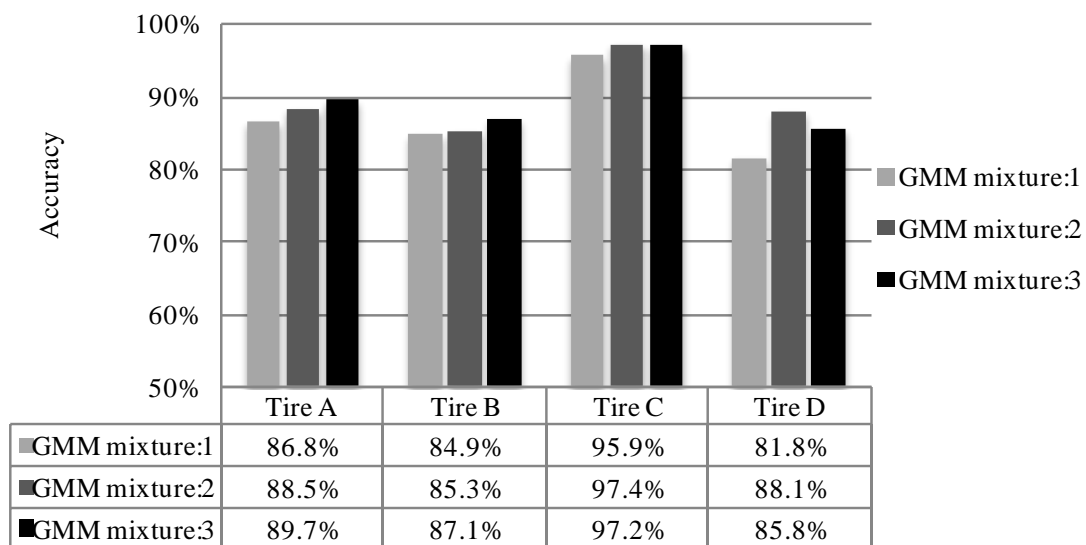


図 40 TireC のデータを学習用に使したときの精度

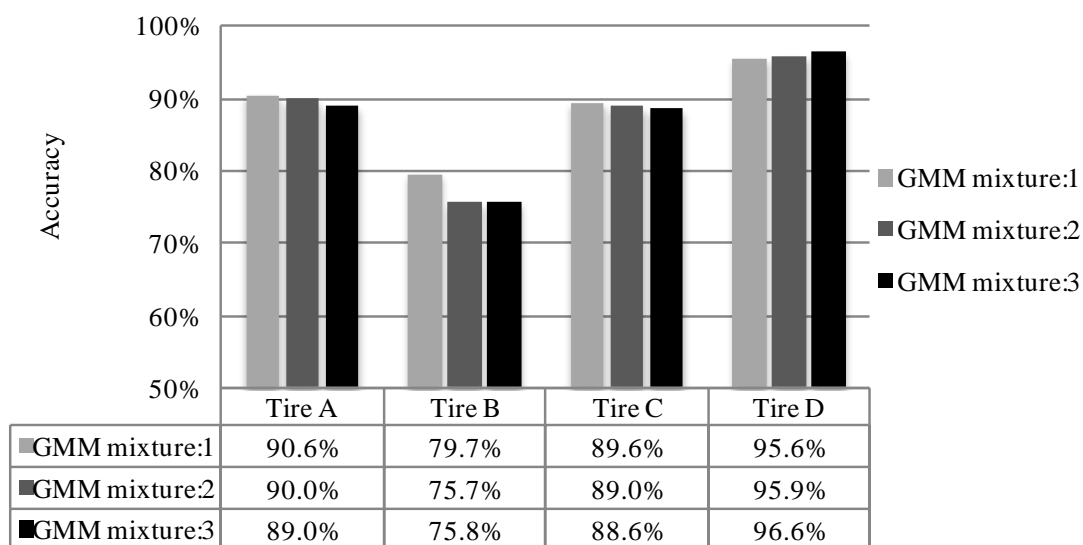


図 41 TireD のデータを学習用に使したときの精度

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0	98.6	100.0	95.7	98.3	98.0	93.1
wet	93.8	81.8	85.0	100.0	100.0	100.0	100.0
snow	90.0	97.3	97.4	98.7	100.0	100.0	-
ice	100.0	100.0	-	-	-	-	-

(a) TireA

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	98.6	100.0	100.0	98.1	97.5	89.9	91.4
wet	86.6	85.3	97.3	87.0	98.6	100.0	94.6
snow	7.8	62.9	93.0	99.6	100.0	88.4	-
ice	0.0	3.3	-	-	-	-	-

(b) TireB

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0	100.0	98.1	98.5	96.5	96.6	97.0
wet	100.0	93.1	55.1	68.0	63.2	58.2	87.1
snow	93.7	99.6	99.6	100.0	100.0	100.0	-
ice	50.0	28.7	-	-	-	-	-

(c) TireC

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	98.4	99.1	100.0	99.5	97.4	97.3	98.8
wet	100.0	98.6	84.1	100.0	83.8	83.6	97.1
snow	85.1	95.1	93.8	99.5	97.5	90.6	-
ice	33.3	66.7	-	-	-	-	-

(d) TireD

表 15 TireA のデータを学習用に使用した時の速度・路面状態毎の精度

GMM の混合数 : 3

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	97.6	98.6	100.0	98.1	98.9	100.0	98.3
wet	96.0	83.6	85.3	77.6	75.4	93.1	92.4
snow	98.3	96.8	94.4	91.4	88.8	66.7	-
ice	0.0	0.0	-	-	-	-	-

(a) TireA

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0	100.0	100.0	100.0	100.0	100.0	100.0
wet	68.2	95.7	100.0	100.0	100.0	100.0	100.0
snow	100.0	97.6	100.0	98.6	100.0	88.4	-
ice	100.0	100.0	-	-	-	-	-

(b) TireB

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0	99.5	99.5	100.0	100.0	100.0	100.0
wet	90.1	93.1	84.1	78.7	72.1	44.8	72.6
snow	95.6	92.0	83.3	88.6	74.1	77.1	-
ice	0.0	0.0	-	-	-	-	-

(c) TireC

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	95.6	99.5	99.5	99.0	99.0	100.0	100.0
wet	94.6	97.2	89.9	97.0	83.8	76.1	
snow	89.3	69.4	58.6	78.2	71.2	41.9	-
ice	0.0	0.0	-	-	-	-	-

(d) TireD

表 16 TireB のデータを学習用に使用した時の速度・路面状態毎の精度

GMM の混合数 : 3

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	95.6	99.1	99.6	98.6	97.3	94.1	66.3
wet	98.0	83.6	85.3	100.0	100.0	97.2	100.0
snow	65.6	93.7	95.3	98.7	89.4	80.0	-
ice	94.5	1.4	-	-	-	-	-

(a) TireA

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	87.0	100.0	100.0	99.5	100.0	100.0	100.0
wet	56.7	88.2	100.0	100.0	100.0	97.3	81.1
snow	65.6	60.9	95.0	95.9	95.9	80.7	-
ice	0.0	0.0	-	-	-	-	-

(b) TireB

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0	100.0	100.0	100.0	100.0	100.0	97.7
wet	100.0	95.8	95.7	100.0	91.3	40.9	100.0
snow	96.2	100.0	98.8	100.0	96.4	87.8	-
ice	100.0	100.0	-	-	-	-	-

(c) TireC

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	90.7	97.7	100.0	97.5	98.5	92.6	76.5
wet	98.7	97.2	100.0	100.0	98.5	98.5	97.1
snow	57.0	86.3	78.9	96.4	86.8	67.9	-
ice	12.1	0.0	-	-	-	-	-

(d) TireD

表 17 TireC のデータを学習用に使用した時の速度・路面状態毎の精度

GMM の混合数 : 3

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	96.6	100.0	99.6	95.3	97.8	98.7	91.4
wet	92.0	86.6	85.3	92.5	88.4	98.6	98.5
snow	19.4	94.1	98.7	100.0	100.0	95.2	-
ice	56.2	0.0	-	-	-	-	-

(a) TireA

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	99.5	100.0	98.6	90.4	71.9	61.2	81.5
wet	53.7	57.4	80.0	92.8	98.6	98.7	93.2
snow	5.2	29.6	72.7	99.6	100.0	93.2	-
ice	0.0	0.0	-	-	-	-	-

(b) TireB

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0	100.0	98.6	91.5	87.9	93.8	99.3
wet	100.0	98.6	87.0	58.7	47.1	59.7	96.8
snow	64.6	95.2	100.0	100.0	100.0	100.0	-
ice	10.6	7.6	-	-	-	-	-

(c) TireC

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0	100.0	97.0	98.5	96.9	98.4	100.0
wet	100.0	100.0	100.0	100.0	82.6	95.5	100.0
snow	47.5	98.4	100.0	100.0	99.2	96.7	-
ice	100.0	100.0	-	-	-	-	-

(d) TireD

表 18 TireD のデータを学習用に使用した時の速度・路面状態毎の精度

GMM の混合数 : 3

4.4 この章の考察とまとめ

4.3.3 で示した結果から，本章で詳説した HMM を用いた路面状態判別方法に関しては，バンドパスフィルタの透過波のパワー値の平均よりも LPC ケプストラム係数のほうが，路面状態判別のためのタイヤ振動波形の特徴をうまく定量化できていることが示された．また 6 状態または 7 状態のモデルの精度が高く，5 状態ではモデルの表現力が不足していることが示唆された．一方判別手法として 2 つの手法を提案したが，その精度の違いはほとんどなかった．

先行研究では，2008-2009 年冬季，及び 2009-2010 年冬季の 2 シーズンにわたり北海道公道において検証試験を行っている．シーズンの平均正答率は 2008-2009 年冬季が 74%であり，2009-2010 年冬季は 82%であった [16] [17] [18]．先行研究では路面状態を 6 分類しており，試験コースも一般道であるので，本研究における実験と同一の条件ではないが，本研究では，4.3.3 で示したように，特徴量を LPC ケプストラム係数とした時，6 状態モデルでは 84.6%~92.6%，7 状態モデルでは 87.2%~92.0% の正答率で路面状態を判別できており，車輪速や接地長の情報なしに先行研究よりも高精度に路面状態を判別できることを示した．しかし精度を路面状態毎，速度毎に見てみると，多数の条件下では 80%以上の高い正答率で判別できていたが，一部正答率の低い条件があった．

4.3.4 ではタイヤサイズ変更に対するロバスト性の評価を行った．TireA のデータを学習用に使用したとき，状態数 7 のモデルでは他のタイヤの正答率は 89%以上であり，1 つのタイヤサイズのデータのみで他サイズのタイヤでも高精度に路面状態の判別ができる可能性が示された．しかし，Tire B のデータで学習した時の正答率，及び他のタイヤのデータで学習した時の Tire B の正答率が他の条件よりも低くなっており，本章で説明した HMM を用いた手法では完全なタイヤサイズに対するロバスト性付与には至っていない．4.3.5 節ではこの問題に対応するために，出力確率関数に用いた GMM の混合数を増加させてその効果を調べた．しかし，パラメータ数増大に伴う過学習に陥り，特に精度を向上させる必要があった凍結路の精度が逆に低下する結果となった．凍結路は表 5 に示すようにデータ数が少ないことが，過学習に陥りやすかった要因と考えられる．

一般車への装着を考えた場合，速度等の走行条件は周囲の交通条件やドライバーの意志によって決まり，タイヤサイズはドライバーの趣向や車種によって決まるので，精度に条件依存性が存在することは好ましくない．上述のような状況はモデルの適応度が路面状態や速度によって変化していることを示唆しており，正

答率を高めるためには、速度・タイヤサイズ変化等も含めてデータ構造にあったモデルを構築することがポイントとなる。HMM は音声認識分野での成功にも見て取れるように、時系列情報を確率モデルで捉え、統計的処理で対処できるため、識別能力に優れており、また認識時のマシン負荷が比較的 low、本研究のようなリアルタイム判別に適していると考えられる。今後可能性のある改良法としては、状態数の最適化、GMM の混合数の最適化、状態遷移時のスキップの許容などが考えられるが、これらモデルの設計法は確立されておらず、試行錯誤的に決定せざるを得ない点が HMM を用いるうえでのデメリットといえる。次章ではパラメータが凸 2 次計画問題の大域最適解として得られる線形識別関数である SVM と時系列を直接扱えるカーネル関数とを組み合わせた手法の説明をして、その有用性について議論する。

第5章 カーネル法を用いたタイヤ振動のモデル化と路面状態判別方法

本章では、まず SVM (Support Vector Machine, サポートベクターマシン) と本研究で用いた時系列を直接的に扱えるカーネルである GA (Global Alignment, グローバルアライメント) について説明する。その後それらを基にした路面状態判別手法について説明する。

5.1 カーネル法 [26] [38]

カーネル法は近年、主として計算機科学の分野で急速に発展してきたデータ解析の方法論である。データの非線形性や高次の情報を扱うことを可能にする系統的方法であり、カーネル法によって様々な線形データ解析法を非線形化する研究がなされてきた [39] [40]。その端緒となったのが SVM を非線形化する研究 [41]であり、その後様々な理論的研究、応用研究が進められ、SVM はカーネル法の代表的な方法となっている。カーネル法のもう一つの利点として、音声など時間伸縮する時系列のような、構造を持つデータに対して直接適用できるという点がある。そのような特徴が、本研究で扱うタイヤ振動波形に適用できると考え、時系列を対象としたカーネルである GA カーネルを用いてタイヤ振動波形を解析し路面状態判別する方法への適用を試みた。

本節では、まず 5.1.1 で SVM について説明し、それを非線形に拡張する一般的な方法について述べる。そして、本研究で用いた GA カーネルとその考え方の基礎となる DTW (Dynamic Time Warping, 動的時間伸縮) カーネルについて 5.1.2 において詳説する。

5.1.1 サポートベクターマシン [26] [42] [43]

SVM (Support Vector Machine, サポートベクターマシン) は、統計的学習理論の枠組みで提案された教師あり学習を用いる識別手法であり、多くの機械学習技術の中でも最も認識性能の優れた学習モデルの一つである。学習時に与えられた訓練データに対してだけでなく、未知の新たなデータに対する認識性能である汎化性能が高いとされ、画像認識 [44] [45] [46] [47]や文字認識 [48] [49] [50] [51], 音声認識 [52] [53] [54] [55] [56], 時系列解析 [57] [58] [59] [60] [61], 周波数分析

[62] [63] [64] [65], バイオインフォマティクス [66] [67] [68] [69] [70], 制御 [71] [72] [73]など様々な分野への応用研究が盛んに行われている．SVM が上記のような長所を有する理由として以下の 4 点があげられる．

- ・ モデルパラメータを学習する際，マージン最大化を基準としている
- ・ モデルパラメータが凸二次計画問題の解として求まる
- ・ 解がスパースであるため，計算コストが比較的小さくて済む
- ・ カーネル法によって非線形に拡張可能である

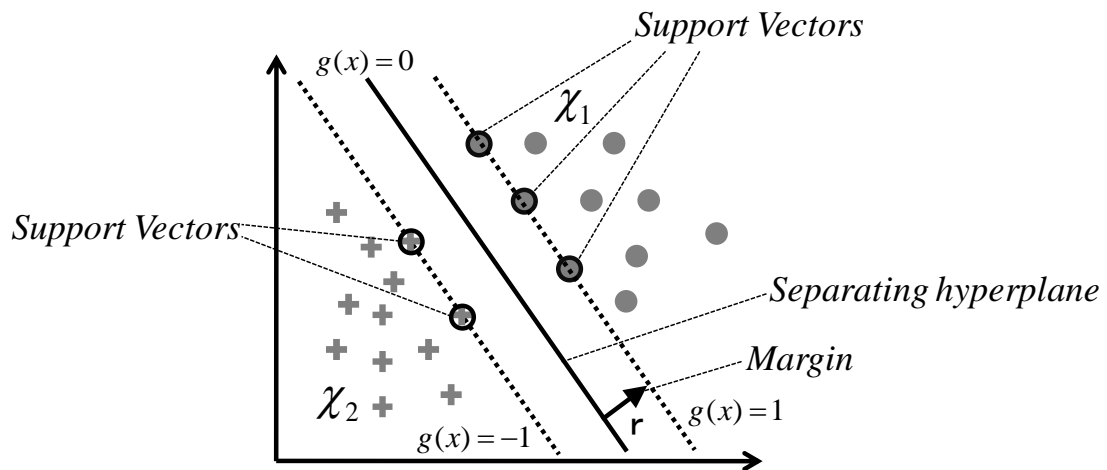


図 42 SVM による 2 値判別

モデルパラメータがマージン最大化を基準として凸二次計画問題の解として求まること，及びその解がスパースであることを，線形モデルを用いた 2 値判別問題を解く過程を示しながら説明する．線形分離可能な学習データの集合： X とそれに対応する教師信号の集合： Y を次のように定義し，これらのデータを 2 つのクラス χ_1 および χ_2 に判別する問題を考える．

$$X = (x_1, x_2, \dots, x_n)^T \quad (5-1-1)$$

$$Y = (y_1, y_2, \dots, y_n)^T = \begin{cases} 1 & \text{if } y_i \in \chi_1 \\ -1 & \text{if } y_i \in \chi_2 \end{cases} \quad (5-1-2)$$

このとき線形 2 値判別器の識別関数を

$$f(X) = \text{sign}(g(X)) \quad (5-1-3)$$

$$g(X) = w^T X + b \quad (5-1-4)$$

と定義する．ただし w は重みベクトル， b はスカラ量であるバイアスパラメータである． $g(X) \geq 1$ のとき $f(X)=1$ を出力して χ_1 に分類し， $g(X) \leq -1$ のとき $f(X)=-1$ を出力して χ_2 に分類する．図 42 はこの問題を模式的に 2 次元で表したものである．一般には訓練データを正確にクラス分類できる解は多数存在しうが，実用上は汎化性能が最も高くなるような解を求めたい．SVM はマージンという概念を導入し，それを最大化するようなモデルパラメータを求める手法であり，汎化性が高いとされている．マージン： r は判別境界 $g(X)=0$ と最も近いデータ点までの距離として定義され，以下のように計算できる．

$$r = \frac{1}{\|w\|} \quad (5-1-5)$$

したがってマージンを最大化する問題は $\|w\|^2$ を最小化する問題と等価であり，SVM は以下のように定式化できる．

$$\begin{cases} \text{minimize} & \frac{1}{2} \|w\|^2 \\ \text{subject to} & y \cdot g(X) \geq 1 \end{cases} \quad (5-1-6)$$

ここで $1/2$ という係数は単に後の計算の単純化のために導入したもので，本質的な意味はない．一見してわかるように目的関数は凸関数なので，極小値が最小値になり，大域最適解を求めることができる．この制約付き最小化問題を，ラグランジュ未定乗数法を用いて双対問題に変換する方法を考える．主問題のラグランジアンは

$$\begin{aligned} L(w, b, \lambda) &= \frac{1}{2} \|w\|^2 - \sum_i \lambda_i \{y_i \cdot g(x_i) - 1\} \\ &= \frac{1}{2} \|w\|^2 - \sum_i \lambda_i \{y_i (w \cdot x_i - b) - 1\} \end{aligned} \quad (5-1-7)$$

である． λ はラグランジュ乗数で $\lambda \geq 0$ である．このラグランジアンを w と b について偏微分し定常性を仮定することにより

$$\frac{\partial L(w, b, \lambda)}{\partial w} = w - \sum_i y_i \lambda_i x_i = 0 \quad (5-1-8)$$

$$\frac{\partial L(w, b, \lambda)}{\partial b} = \sum_i y_i \lambda_i = 0 \quad (5-1-9)$$

という関係を得る．式(5-1-8)から，識別関数の重みベクトルは以下のように得られる．

$$w = \sum_i y_i \lambda_i x_i \quad (5-1-10)$$

式(5-1-9)および(5-1-10)を(5-1-7)に代入すると，式(4-2-6)の双対問題を得る．

$$\begin{cases} \text{maximize} & \sum_i \lambda_i - \frac{1}{2} \sum_{i,j} \lambda_i \lambda_j y_i y_j x_i x_j \\ \text{subject to} & \sum_i y_i \lambda_i = 0 \quad \lambda_i \geq 0 \end{cases} \quad (5-1-11)$$

このとき KKT 条件（Karush-Kuhn-Tucker 条件） [74] [75]を適用すると，以下に示す 3 つの条件が成り立つ．

$$\lambda_i \geq 0 \quad (5-1-12)$$

$$y_i \cdot g(x_i) - 1 \geq 0 \quad (5-1-13)$$

$$\lambda_i \{y_i \cdot g(x_i) - 1\} = 0 \quad (5-1-14)$$

特に式(5-1-13)は KKT 相補条件と呼ばれ，全てのデータ点において， $\lambda_i=0$ ，または $y_i \cdot g(x_i)=1$ が成り立つことを示している．このことは， $\lambda_i \neq 0$ となるデータ点はマージンが 1 であり，分離超平面に最も近接した点：サポートベクトルであることを意味する．一方 $\lambda_i=0$ となるデータ点は式(5-1-10)において，重みベクトル w に何の影響も与えない．つまり，学習によってモデルを構築した後では，サポートベクトル以外のデータの情報は不要となるので，上記最適化問題の解はスパースである．

ここまでは学習データが線形分離可能であると仮定したが，実際の問題ではクラスの条件付き確率分布が重なる場合が大多数である．そのような場合，このままでは最適化問題を解くことはできないので，一部の学習データの誤判別を許

容するような修正が必要になってくる．このような修正をハードマージン制約のソフトマージンへの緩和と呼ぶ．具体的には式(5-1-13)で示した条件式にスラック変数： $\xi_i(i=1,2,\cdots,n)\geq 0$ を導入し，主問題(5-1-6)を次のように修正する．

$$\begin{cases} \text{minimize} & \frac{1}{2}\|w\|^2 + C\sum_i \xi_i \\ \text{subject to} & y \cdot g(X) \geq 1 - \xi_i \end{cases} \quad (5-1-15)$$

式(5-1-15)では，条件式に ξ_i を導入することでデータ点がマージン内に侵入することを許す代わりに，主問題でマージン境界からの距離に応じたペナルティを与えている．それを模式的に表したものが図 43 である．正しく分類できているデータ点では $\xi_i=0$ であり，マージン内部に侵入したデータ点では $0<\xi_i\leq 1$ となる．また，識別境界を越えて，誤ったクラスへ分類されたデータ点では $\xi_i>1$ となる．つまり $y_i \cdot g(x_i)=1$ が成り立つ場合， $\xi_i=0$ が成立し，それ以外の場合には $\xi_i=1 - y_i \cdot g(x_i)$ が成立するので， ξ_i を誤差関数として捉えると図 44 に示すようなヒンジ型の関数となる． C は ξ_i を用いて表されるペナルティとマージンの大きさの間のトレードオフを制御するパラメータであり $C>0$ である． $C\rightarrow\infty$ の極限では分離可能なデータに対するハードマージン SVM の最適化問題と等しくなる．

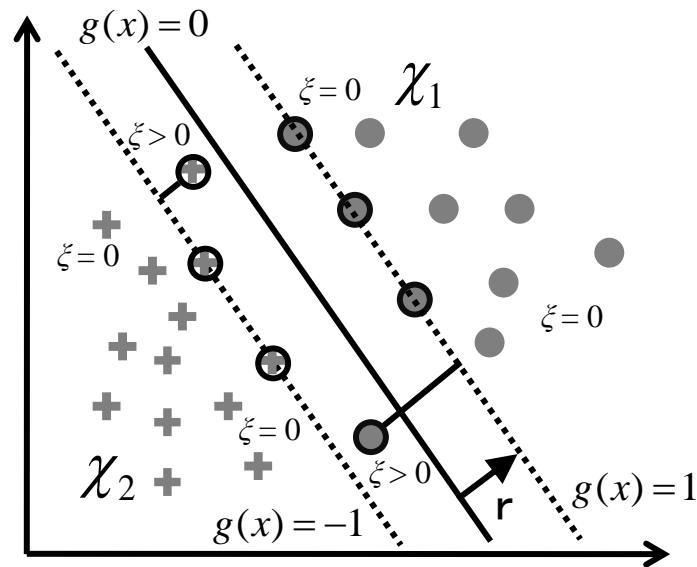


図 43 スラック変数： ξ の導入によるソフトマージンへの緩和

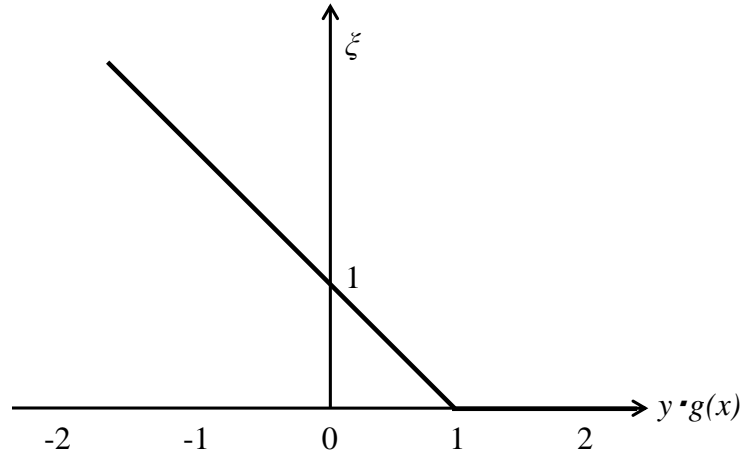


図 44 ヒンジ型誤差関数

ハードマージン制約の時と同様に，式(5-1-15)で示した制約付き最小化問題の双対化を考える．主問題のラグランジアンは以下のようになる．

$$L(w, b, \xi, \lambda, \mu) = \frac{1}{2} \|w\|^2 + C \sum_i \xi_i - \sum_i \lambda_i \{y_i \cdot (w \cdot x_i - b) - 1 + \xi_i\} - \sum_i \mu_i \xi_i \quad (5-1-16)$$

$\lambda \geq 0$ と $\mu \geq 0$ はラグランジュ乗数である．このラグランジアンを w と b および $\{\xi_i\}$ について偏微分し定常性を仮定すると

$$\frac{\partial L}{\partial w} = w - \sum_i y_i \lambda_i x_i = 0 \quad (5-1-17)$$

$$\frac{\partial L}{\partial b} = \sum_i y_i \lambda_i = 0 \quad (5-1-18)$$

$$\frac{\partial L}{\partial \xi} = C - \lambda_i - \mu_i = 0 \quad (5-1-19)$$

となる．この結果を式(5-1-16)に代入すると双対型のラグランジアンを得る．

$$\tilde{L}(\lambda) = \sum_i \lambda_i - \frac{1}{2} \sum_{i,j} \lambda_i \lambda_j y_i y_j x_i x_j \quad (5-1-20)$$

また， $\lambda \geq 0$ と $\mu \geq 0$ および式(5-1-19)から， $\lambda \leq C$ が成り立つ．したがって，解くべき制約付き最小化問題の双対問題は，

$$\begin{cases} \text{maximize} & \sum_i \lambda_i - \frac{1}{2} \sum_{i,j} \lambda_i \lambda_j y_i y_j x_i x_j \\ \text{subject to} & \sum_i y_i \lambda_i = 0 \quad 0 \leq \lambda_i \leq C \end{cases} \quad (5-1-21)$$

である．ハードマージン SVM との相違点は λ に関する制約条件のみであり， $C \rightarrow \infty$ の極限においては，ハードマージン SVM と同一である．

ここまでは線形モデルを考えてきたが，SVM はカーネル法を導入することにより非線形へ拡張させることができる．式(5-1-11)および(5-1-21)で示した双対問題において，各データ点間の距離は入力空間における内積で評価される．これを別の高次元特徴空間に写像後の内積に置き換えることによって，元の入力空間において，識別関数を非線形化することを考える．つまり式(5-1-20)で示した双対型のラグランジアンを以下のように書き換える．

$$\tilde{L}(\lambda) = \sum_i \lambda_i - \frac{1}{2} \sum_{i,j} \lambda_i \lambda_j y_i y_j \phi(x_i) \phi(x_j) \quad (5-1-22)$$

ただし， ϕ は特徴空間への写像を示す．明示的に高次元特徴空間内で内積を扱うには莫大な計算コストがかかるが，カーネル関数は高次元空間への写像後の内積を入力空間内で直接計算することができる．

$$K(x_i, x_j) = \langle \phi(x_i) \cdot \phi(x_j) \rangle \quad (5-1-23)$$

カーネル関数： K を使用すれば，データを陰に特徴空間へ写像できるため，特徴空間の次元は必ずしも計算に影響しない．これにより，特徴写像の評価に内在する計算コストの問題を回避することができる．結局非線形 SVM の制約付き最小化問題の双対問題は，

$$\begin{cases} \text{maximize} & \sum_i \lambda_i - \frac{1}{2} \sum_{i,j} \lambda_i \lambda_j y_i y_j K(x_i, x_j) \\ \text{subject to} & \sum_i y_i \lambda_i = 0 \quad 0 \leq \lambda_i \leq C \end{cases} \quad (5-1-24)$$

と表される．

ここまで線形判別器である SVM に関し，ハードマージンからソフトマージン，

線形から非線形への拡張を説明してきた．これらはすべて凸二次計画問題で表され，勾配法 [76]を用いた最適化技法によって解くことができる．最も単純には最急降下法 [76] [77] [78]を用いて，逐次的にラグランジュ乗数： λ を更新し最適解を求められる．

$$\lambda_{n+1} = \lambda_n + \eta \cdot \frac{\partial L}{\partial \lambda} \quad (5-1-25)$$

目的関数 L を式(5-1-24)の主問題と考えると

$$\lambda_{n+1} = \lambda_n + \eta \cdot \left(1 - \sum_{i,j} \lambda_j y_i y_j K(x_i, x_j) \right) \quad (5-1-26)$$

となり，全てのデータ点が KKT 条件を満たすまで計算を繰り返して， λ の最適値を求める．それを式(5-1-17)に代入することで，重みベクトル w の最適解が求まる． $g(X)$ を構成するもう一つの要素であるバイアスパラメータ b は，任意のサポートベクトル x_i について， $y_i \cdot g(x_i)=1$ が成り立つことを使って求められる．

$$y_j \left(\sum_{i \in S} \lambda_i y_i K(x_i, x_j) + b \right) = 1 \quad (5-1-27)$$

ここで S はサポートベクトルの添え字からなる集合である．理論的には任意のサポートベクトル x_i について式(5-1-27)を解けば b は求まるが，計算上の誤差の影響を減らすために，全てのサポートベクトルに対して平均を取ってもよい．

$$b = \frac{1}{N_T} \sum_{j \in T} \left(y_j - \sum_{i \in S} \lambda_i y_i K(x_i, x_j) \right) \quad (5-1-28)$$

ただし， T は $0 < \lambda_i < C$ となるデータ点の添え字の集合である．

しかしこの方法は毎回全データを使った高次の行列演算が必要であり，データ数や次元数の増大の伴い多量のメモリと計算時間が必要となる．この問題を解決する最適化手法が SMO(Sequential Minimal Optimization, 逐次最小問題最適化法) [79]であり，現在最も良く使われる実用的な SVM の最適化手法の一つである．SMO は全てのデータ点の中から，ただ 2 つのデータ点に対応するラグランジュ乗数を選択し，その 2 つのラグランジュ乗数に関する部分問題を逐次解いていくことで最終的な最適解を得る手法である．SMO は各ステップにおいて，まず最適化

する 2 つのラグランジュ乗数 λ_1 と λ_2 を選択する．次に，他のすべてのラグランジュ乗数は定数とみなして目的関数を最大化することを考える．このとき目的関数は，

$$\begin{aligned}
 \tilde{L}(\lambda) &= \sum_i \lambda_i - \frac{1}{2} \sum_{i,j} \lambda_i \lambda_j y_i y_j x_i x_j \\
 &= \lambda_1 + \lambda_2 + \sum_{i=3}^N \lambda_i - \frac{1}{2} \sum_{i=1}^2 \sum_{j=1}^2 \lambda_i \lambda_j y_i y_j x_i x_j \\
 &\quad - \frac{1}{2} \sum_{i=1}^2 \sum_{j=3}^N \lambda_i \lambda_j y_i y_j x_i x_j \\
 &\quad - \frac{1}{2} \sum_{i=3}^N \sum_{j=1}^2 \lambda_i \lambda_j y_i y_j x_i x_j \\
 &\quad - \frac{1}{2} \sum_{i=3}^N \sum_{j=3}^N \lambda_i \lambda_j y_i y_j x_i x_j
 \end{aligned} \tag{5-1-29}$$

という形に変換できる．これを展開して λ_2 について偏微分し定常性を仮定して得た結果を目的関数 \tilde{L} に代入すると，

$$\lambda_2^{new_temp} = \lambda_2^{old} - \frac{y_2(E_1 - E_2)}{\eta} \tag{5-1-30}$$

という λ_2 の更新式を得ることができる．ただし，

$$E_i = g(x_i) - y_i \tag{5-1-31}$$

である．一方，式(5-1-24)式の制約条件は，図 45 のように λ_2 の取りうる範囲を制限する．

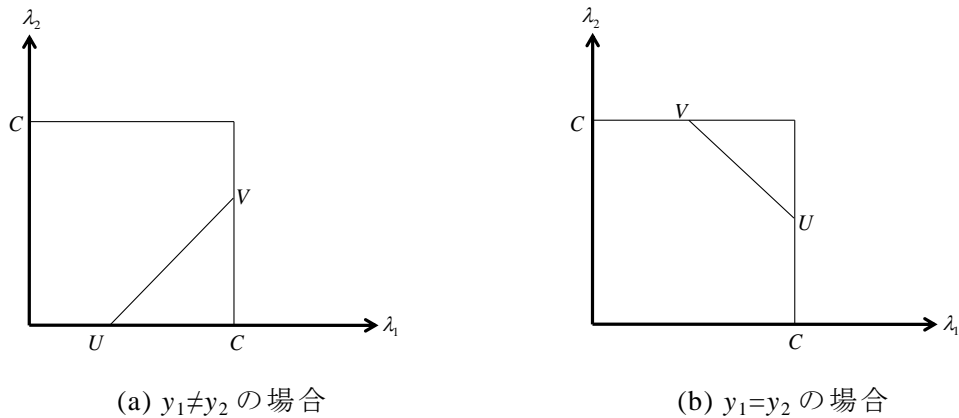


図 45 ラグランジュ未定乗数が満たす制約

λ_2^{new} が取り得る値の範囲は

$$U \leq \lambda_2^{new} \leq V \quad (5-1-32)$$

である．ただし U と V は， $y_1 \neq y_2$ の場合，

$$U = \max(0, \lambda_2^{old} - \lambda_1^{old}) \quad (5-1-33)$$

$$V = \min(C, C + \lambda_2^{old} - \lambda_1^{old}) \quad (5-1-34)$$

と定義され， $y_1 = y_2$ の場合，

$$U = \max(0, \lambda_2^{old} + \lambda_1^{old} - C) \quad (5-1-35)$$

$$V = \min(C, \lambda_2^{old} + \lambda_1^{old}) \quad (5-1-36)$$

である．結局，式(5-1-30)でループ毎に更新される λ_2 は，式(5-1-32)の制約を受けて以下のように求められる．

$$\lambda_2^{new} = \begin{cases} H & \text{if } \lambda_2^{new_temp} \geq H \\ \lambda_2^{new} & \text{if } L < \lambda_2^{new_temp} < H \\ L & \text{if } \lambda_2^{new_temp} \leq L \end{cases} \quad (5-1-37)$$

式(5-1-24)式の制約条件から， $\lambda_1^{old} y_1 + \lambda_2^{old} y_2 = \lambda_1^{new} y_1 + \lambda_2^{new} y_2$ であるから， λ_1^{new} は求められた λ_2^{new} を用いて以下のように求められる．

$$\lambda_1^{new} = \lambda_1^{old} + y_1 y_2 (\lambda_2^{old} - \lambda_2^{newclipped}) \quad (5-1-38)$$

このようにして求めた λ_1^{new} と λ_2^{new} を用いて，バイアスパラメータ b も逐次更新していく． λ_1 が識別境界上にない場合， x_1 に対する SVM の出力は y_1 となるように強制されるので，その時の閾値 b_1 は

$$b_1 = E_1 + y_1 (\lambda_1^{new} - \lambda_1^{old}) K(x_1, x_1) + y_2 (\lambda_2^{new} - \lambda_2^{old}) K(x_1, x_2) + b \quad (5-1-38)$$

となる．一方， λ_2 が識別境界上にない場合， x_2 に対する SVM の出力は y_2 となるように強制されるので，その時の閾値 b_2 は

$$b_2 = E_2 + y_1 (\lambda_1^{new} - \lambda_1^{old}) K(x_1, x_2) + y_2 (\lambda_2^{new} - \lambda_2^{old}) K(x_2, x_2) + b \quad (5-1-39)$$

λ_1^{new} と λ_2^{new} が識別境界上のデータ点に対応するラグランジュ乗数である場合，ま

たは $U \neq V$ であるとき, b_1 と b_2 の区間は全て KKT 条件を満たす閾値となり得る. また上記以外の場合は $b_1 = b_2$ となるので, SMO では b_1 と b_2 の中間値を閾値とする. このようにして, 2 点ずつデータを選択し, 最適化するステップを全てのデータ点が KKT 条件を満たすまで繰り返すことによって, 全体を最適化する. 上述のように高次の行列演算が不要なので, ループ回数は増えるが, 1 ループの計算時間を大幅に短縮できるので, 結果として高速に収束する.

5.1.2 GA(Global Alignment)カーネル [80] [81]

本項では本研究で用いた GA(Global Alignment)カーネルについて説明する. GAカーネルは DTW(Dynamic Time Warping)カーネル [48] [82]に影響を受けて開発されたものであり両者の関係は深いので, まず DTW カーネルについて説明する. DTW は 2 つの系列間の類似度を測定する, 有用な距離尺度であり, 音声認識や手書き文字認識等の様々な分野で幅広く利用されている [83] [84]. 動的計画法を用いて, 系列間の距離が最小となるよう最適な経路を選択することができるため, 系列が時間軸上で非線形にワープするような場合でも, 系列長やサンプリングレートが異なる時系列間の類似度を計算することが可能な手法である.

上記の枠組みで計算される系列間の距離である DTW 距離の計算方法を以下に述べる. 2 つの時系列 x と y が与えられ, その特徴ベクトルの系列をそれぞれ $a=(a_1, a_2, \dots, a_n)$ と $b=(b_1, b_2, \dots, b_m)$ とするとき, a のアライメントを π_1 , b のアライメントを π_2 とし, 次のように定義する.

$$\begin{aligned} 1 &= \pi_1(1) \leq \pi_1(2) \leq \dots \leq \pi_1(p) = n \\ 1 &= \pi_2(1) \leq \pi_2(2) \leq \dots \leq \pi_2(p) = m \end{aligned} \tag{5-1-40}$$

ただし p はアライメントの長さ $|\pi|$ である. また π の増分は最大 1 で, π_1 と π_2 は同時に同じ値を繰り返さないという以下の制約を与える.

$$\begin{aligned} \pi_1(i+1) &\leq \pi_1(i) + 1 \\ \pi_2(j+1) &\leq \pi_2(j) + 1 \\ \{\pi_1(i+1) - \pi_1(i)\} + \{\pi_2(i+1) - \pi_2(i)\} &\geq 1 \end{aligned} \tag{5-1-41}$$

(5-1-40)と(5-1-41)が示すことは、 i 番目のパスから $i+1$ 番目のパスへ移動する経路は図 46 に示すような 3 つの経路のみが許可されるということである。

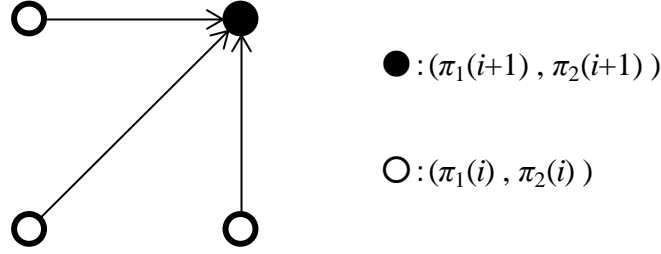


図 46 経路の制約

このときアライメント π に対する DTW 距離は

$$S(\pi) = \sum_{i=1}^{|\pi|} \kappa(a_{\pi_1(i)}, b_{\pi_2(i)}) \quad (5-1-42)$$

と表される．ただし、 κ は正定値カーネルである． a と b の系列を比較するとき可能なすべてのアライメントの集合を $A(a, b)$ とするとき、DTW カーネルは代表的に次の 2 式で表される [48] [82]．

$$k_{DTW_1} = \exp\left(\frac{1}{|\pi^*|} S(\pi^*)\right) = \exp\left(-\arg \max_{\pi \in A(a, b)} \frac{1}{|\pi|} \sum_{i=1}^{|\pi|} \|a_{\pi_1(i)} - b_{\pi_2(i)}\|^2\right) \quad (5-1-43)$$

$$k_{DTW_2} = \exp\left(\frac{1}{|\pi^*|} S(\pi^*)\right) = \arg \max_{\pi \in A(a, b)} \frac{1}{|\pi|} \sum_{i=1}^{|\pi|} \exp\left(\frac{\|a_{\pi_1(i)} - b_{\pi_2(i)}\|^2}{\sigma^2}\right) \quad (5-1-44)$$

両者とも動的計画法により $S(\pi)$ が最大となるような最適なパスである π^* を選択する部分については同一であり、正定値カーネル κ をユークリッド距離とするのかガウシアンカーネルとするのかの違いである．一方 GA カーネルでは最適なパスを選択するのではなく、全ての可能なパスについて和を取ることで系列間の類似度を求める．その利点は 2 つあり、一つはパスに対して $\arg \max$ を取らないことで、グラム行列の正定値性が保証されることであり、もう一つは、最適パスの周辺パ

スに含まれる有用な情報も考慮できる点である [80] [81]. ただし, GA カーネルは一般に対角優位性が高く, [80]においてはそれを是正するためカーネルの対数を取っており, その操作によりカーネルの正定値性は担保されなくなる点を記載しておく.

$$K_{GA} = \sum_{\pi \in A(a,b)} \exp(S(\pi)) = \sum_{\pi \in A(a,b)} \prod_{i=1}^{|\pi|} \kappa(a_{\pi_1(i)}, b_{\pi_2(i)}) \quad (5-1-45)$$

(5-1-45)式は, 全ての可能なアライメントに対するソフトマックスを取っていることを示している. つまりハイスコアを持つアライメントだけではなく, そのほかの効果的なアライメントも広範囲に含めることによって系列の類似性を評価している. 本研究において, 第3章で述べたような特徴を持つタイヤ振動波形の類似性を評価する場合, 路面踏み込みや蹴り出しといった各領域内の類似性の評価が重要な意味を持つので, 最適なパスだけではなく, その周辺のパスにも有意な情報が含まれていると考えられる. このような観点から, 最適なパス以外の情報を考慮していない DTW カーネルよりも, すべてのパスを考慮している GA カーネルのほうが本研究には適していると考え, これを採用することとした. 次節では具体的なタイヤ振動解析への適用方法について説明する

5.2 カーネル法を用いた判別方法

本節ではカーネル法を用いた SVM による判別方法について説明する. 第2章で述べたように, 車輪速や接地長の変化に伴い, タイヤ振動波形の時系列は時間伸縮するため, サンプリングレート固定でデータを収録し, 一定のサンプル周期で窓関数を掛け特徴ベクトルを算出する一般的な手法を用いた場合, そのデータ系列の長さは一定ではない. 先行研究 [16] [17] [18]では, タイヤ振動波形に現れるピーク位置を基準として窓掛けする位置を経験的に定め, その窓の位置や長さを車輪速の関数として定義することにより, 波形の時間伸縮に対応していた. したがって, 別途車輪速を計測する必要があるほか, 高精度にピーク位置を検出しなければならない等, 実用化する上でコスト的に不利な状況であった. 5.1 節で述べたように, GA カーネルは長さの異なる時系列を直接的に扱うことができるので, 本研究では GA カーネルを用いて上記のような特徴を持つタイヤ振動情報のみを使って, 波形から得られるデータ系列同士を直接的に比較し, SVM により

判別するシステムの構築を試みた．

図 47 は時速 60km で DRY アスファルトを走行した時のタイヤ振動波形と，時速 90km で DRY アスファルトを走行した時のタイヤ振動波形を比較したものである．波形は非定常性が強く，その特徴は時間とともに変化するため，長さが異なるデータを比較する場合，系列のアライメントとる必要がある．5.1 で述べたように GA カーネルで系列を比較する場合，全ての取り得るパスの和を取ることで，系列同士の類似度を測る．したがって車輪速情報やピーク位置情報などを必要としない．

図 48 は 6×9 グリッドにおける全てのローカルカーネルを示したものである．ローカルカーネル κ は

$$\kappa_{i,j} = \kappa(a_i, b_j) \quad (5-2-1)$$

であり，本研究ではガウシアンカーネル

$$\kappa(a_i, b_j) = \exp\left(-\frac{1}{\sigma^2} \|a_i - b_j\|^2\right) \quad (5-2-2)$$

を用いた．ただし， a は x_i の系列， b は x_j の系列， π はアライメント（時系列同士の位置合わせの仕方）， $A(a,b)$ は可能な全てのアライメントを示す．したがって，GA カーネルは次式で与えられる．

$$\begin{aligned} K_{GA}(x_i, x_j) &= \sum_{\pi \in A(a,b)} \prod_{i=1}^{|\pi|} \kappa(a_{\pi_1(i)}, b_{\pi_2(i)}) \\ &= \sum_{\pi \in A(a,b)} \prod_{i=1}^{|\pi|} \exp\left(-\frac{1}{\sigma^2} \|a_i - b_j\|^2\right) \end{aligned} \quad (5-2-3)$$

このように算出したカーネル関数を，4-2-23 式の SVM の目的関数に代入し，最適な識別関数を得る．SVM は本来 2 値判別器であるので，本研究で問題となる多クラスへの拡張には one-vs-all 方式 [85] [86] を採用した．つまり，ドライアスファルトとその他を分類する判別器，WET asphalt とその他を分類する判別器，

SNOW とその他を分類する判別器，ICE とその他を分類する判別器をそれぞれ用意し，最もスコアが高かった SVM に対応する路面状態に判別する．

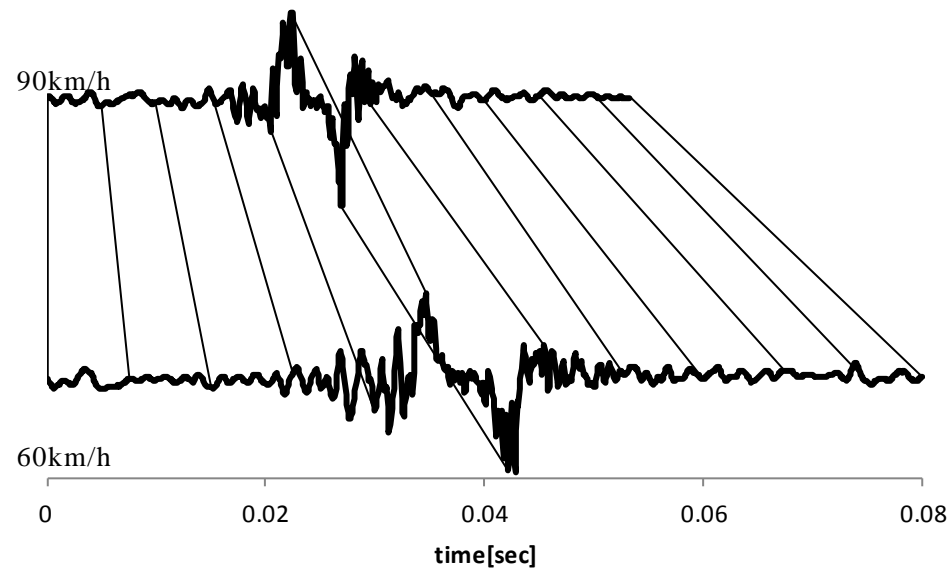


図 47 速度が異なる振動波形の比較例

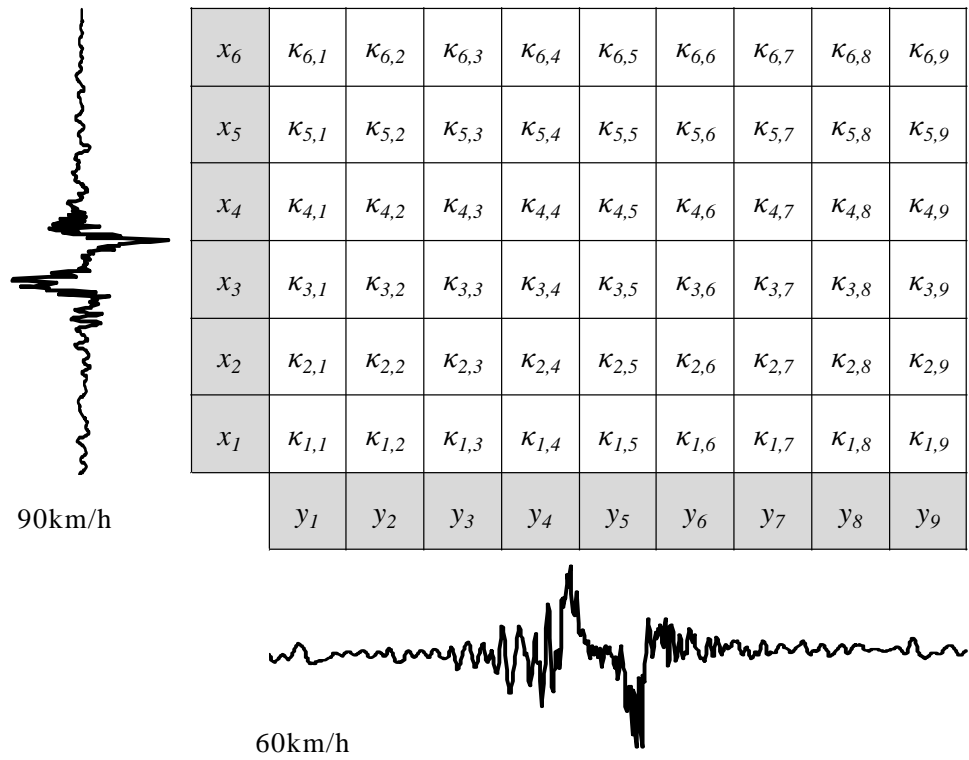


図 48 6×9 グリッドにおける全てのローカルカーネル

5.3 実験

4 章で説明した HMM を用いた手法と同様に路面状態をドライアスファルト，ウェットアスファルト，圧雪，凍結の 4 種に判別する問題について，4.3.1 で説明したものと同一のデータを用いて認識テストを行った．

GA カーネル行列（グラム行列）は一般に対角優位性が強く，つまり自身との比較である $K_{GA}(i,i)$ は他者との比較である $K_{GA}(i,j)$ に比べて数桁大きい値を取ることが [80] で述べられている．図 49 に本研究で用いた特徴量を LPC ケプストラム係数とし，タイヤ振動データから算出した GA カーネル行列の等高線図を示す．対角成分以外は値を持たず (=0)，対角優位性が強いので，実際に実験に使用したグラム行列： $G_{GA}(i,j)$ は，以下のように求めた．

$$K'_{GA} = \log K_{GA} \quad (5-3-1)$$

$$K''_{GA}(i,j) = K''_{GA}(j,i) = \exp \left[K'_{GA}(i,j) - \frac{1}{2} \{ K'_{GA}(i,i) + K'_{GA}(j,j) \} \right] \quad (5-3-2)$$

$$G_{GA} = K''_{GA} - I * e_{\min} \quad (5-3-3)$$

ただし， I は単位行列， e_{\min} は K''_{GA} の最小固有値である．グラム行列は対数を取ることによって正定値性が保たれなくなるが，本研究では対角優位性を是正することを優先した．規格化後のグラム行列の等高線図を図 50 に示す．

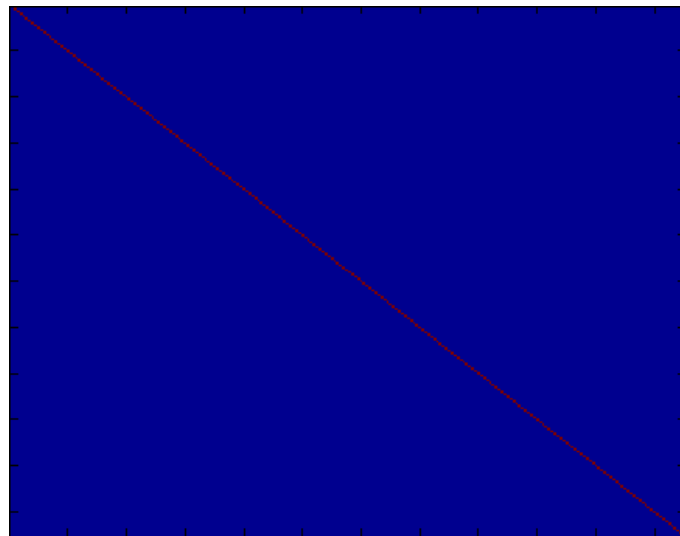


図 49 タイヤ A を学習データとした時の GA カーネル行列

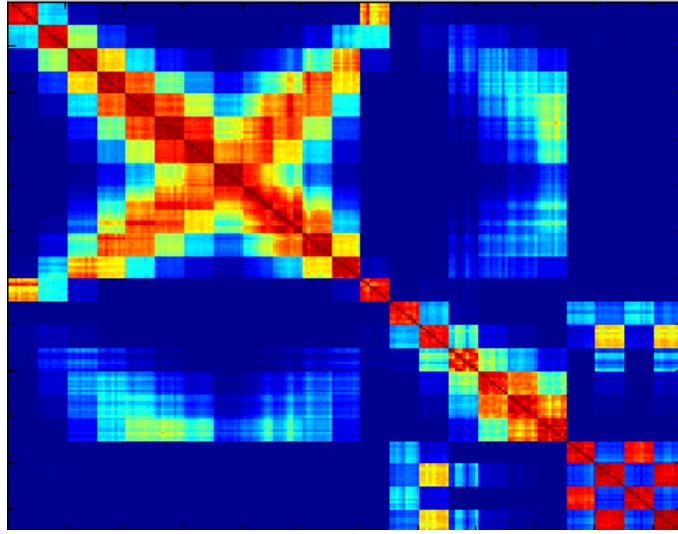


図 50 対数を取り最小固有値を減算した GA カーネル行列

5.3.1 GA カーネルを用いた手法の精度

4.3.3 で示した HMM に基づく手法と同様に，表 3 に示すタイヤ 4 種の内 3 種のタイヤの全データを学習用，残りの 1 種のタイヤの全データをテスト用とし，認識テストを行った．表 5 に示すように，路面条件毎データ数は一様ではなく，且つマルチクラスへ対応するため 1 vs. all を採用しているため，学習の際に正例と負例の数は一致せず，問題の対称性が失われている．[87]では K 個のクラスに分類する場合，正例に対する識別関数の値は $+1$ ，負例に対しては $-1/(K-1)$ となるように学習することを提案している．本研究では正例数を n_1 ，負例数を n_2 とした時，正例に対する識別関数の値を n_2/n_1 ，負例に対しては -1 となるように学習した．図 51 は GA カーネルを用いた手法の認識テスト結果である．特徴量をバンドパスフィルタ透過波のパワー値の平均と LPC ケプストラム係数とした時の正答率と，上記 2 つの特徴量に関してそれぞれ算出したカーネル関数の和を取ったモデルについての正答率を算出した．なお，GA カーネルのチューニングパラメータ： σ と SVM のコストパラメータ： C の設定については付録に記載した．また，ここで言う正答率とは，タイヤが 1 回転するごとに出力される接地面近傍の波形から，上記の方法で路面状態を判別し，それを一つのデータ点として判別された結果と正解とを比較し，正答数をデータ総数で除したものである．

図 51 に示すように，特徴量をバンドパスフィルタ透過波のパワー値の平均としたときと，LPC ケプストラム係数とした時の正答率は，すべてのタイヤ条件で 95%以上であり，特徴量による違いはほとんどない．バンドパスフィルタ透過波のパワー値の平均としたときのカーネルと LPC ケプストラム係数とした時のカーネルの和を取ったモデルの正答率は，タイヤ A でやや低下しているが，全てのタイヤ条件で 90%以上であり，GA カーネルを用いた手法では，高精度に路面状態を判別できることが示された．

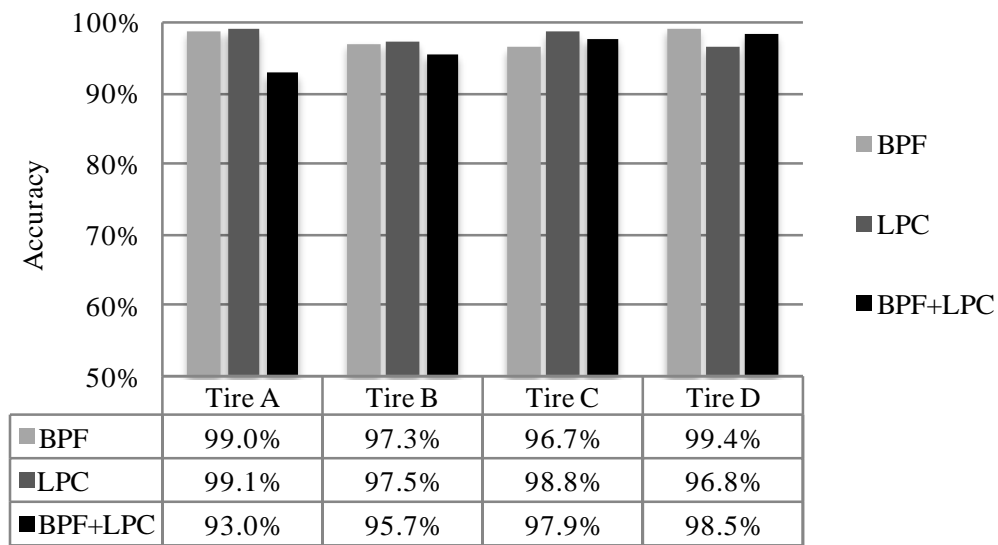


図 51 GA カーネルを用いた手法の認識テスト結果

より詳細に試験結果を分析するため，走行条件毎の正答率を調べた．表 19 は特徴量をバンドパスフィルタ透過波のパワー値の平均とした時の正答率を速度・路面状態毎に示したものである．TireA と TireD は全ての条件において高い正答率を示しているが，TireB および TireC の低速域の凍結は正答率が低い．一方，表 20 は特徴量を LPC ケプストラム係数とした時の正答率を速度・路面状態毎に示したものである．TireD の凍結 40km/h を除く全ての条件において 80%以上の高精度で判別できている．このように特徴量をバンドパスフィルタ透過波のパワー値の平均とした時と LPC ケプストラム係数とした時の正答率の条件依存性には違いがある．これをうまく相殺するために，両者のカーネル関数の和を取ったモデルについて評価し，正答率を速度・路面状態毎に示したものが表 21 である．特徴量をバンドパスフィルタ透過波のパワー値の平均とした時に精度が低かった TireC の凍結 30km/h や LPC ケプストラム係数とした時の TireD の凍結 40km/h は精度が上昇したが，TireB の低速域の凍結や TireC の凍結 40km/h は実用的な精度にはなっていない．

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	99.5%	100.0%	98.7%	97.7%
wet	98.5%	98.6%	95.7%	100.0%	98.4%	94.0%	100.0%
snow	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	-
ice	94.5%	84.5%	-	-	-	-	-

(a) TireA

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
wet	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	98.6%
snow	100.0%	100.0%	99.6%	100.0%	100.0%	97.5%	-
ice	1.6%	63.3%	-	-	-	-	-

(b) TireB

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
wet	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
snow	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	-
ice	45.5%	0.0%	-	-	-	-	-

(c) TireC

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	99.5%	100.0%	100.0%	100.0%	100.0%	98.8%
wet	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
snow	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	-
ice	86.4%	86.4%	-	-	-	-	-

(d) TireD

表 19 各速度・路面状態における GA カーネルを用いた手法の精度

特徴量：バンドパスフィルタ透過波のパワー値の平均

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	99.1%	99.5%	100.0%	99.5%	100.0%	98.9%
wet	100.0%	98.6%	100.0%	98.5%	96.7%	88.1%	100.0%
snow	100.0%	100.0%	100.0%	100.0%	98.4%	98.2%	-
ice	95.9%	100.0%	-	-	-	-	-

(a) TireA

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	99.5%	100.0%	100.0%
wet	100.0%	100.0%	100.0%	100.0%	100.0%	98.5%	82.4%
snow	83.1%	91.3%	97.1%	100.0%	100.0%	95.5%	-
ice	93.5%	100.0%	-	-	-	-	-

(b) TireB

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
wet	100.0%	97.2%	98.6%	96.0%	100.0%	92.5%	82.3%
snow	98.7%	100.0%	100.0%	100.0%	100.0%	100.0%	-
ice	97.0%	84.8%	-	-	-	-	-

(c) TireC

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	99.5%	99.1%	100.0%	100.0%	100.0%	99.5%	100.0%
wet	100.0%	100.0%	98.6%	100.0%	100.0%	100.0%	100.0%
snow	100.0%	100.0%	98.4%	98.4%	99.2%	84.1%	-
ice	100.0%	27.3%	-	-	-	-	-

(d) TireD

表 20 各速度・路面状態における GA カーネルを用いた手法の精度

特徴量：LPC ケプストラム係数

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	98.6%	97.8%	64.5%	20.6%
wet	97.0%	91.7%	95.7%	100.0%	100.0%	100.0%	100.0%
snow	100.0%	100.0%	100.0%	100.0%	99.5%	95.2%	-
ice	98.6%	98.6%	-	-	-	-	-

(a) TireA

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
wet	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	98.6%
snow	88.3%	92.9%	93.0%	99.5%	100.0%	89.4%	-
ice	46.8%	46.7%	-	-	-	-	-

(b) TireB

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
wet	100.0%	98.6%	100.0%	100.0%	100.0%	100.0%	100.0%
snow	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	-
ice	100.0%	3.0%	-	-	-	-	-

(c) TireC

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	99.4%
wet	98.7%	98.6%	100.0%	100.0%	100.0%	100.0%	100.0%
snow	62.5%	100.0%	100.0%	100.0%	100.0%	100.0%	-
ice	100.0%	100.0%	-	-	-	-	-

(d) TireD

表 21 各速度・路面状態における GA カーネルを用いた手法の精度
特徴量：バンドパスフィルタ透過波のパワー値の平均，LPC ケプストラム係数

5.3.2 サイズロバスト性の検証

次に 1 種のタイヤのデータで学習したモデルが，他のタイヤ種のデータの判別にも適用できるかを調べた．学習用データとテスト用データを以下のように設定した．表 3 に示すタイヤ 4 種の内 1 種を選び，路面状態ごとに，すべての速度域が含まれるように，総データ数の 3 分の 2 を抜粋する．これをまとめて学習用データとする．上記の学習用データに採用されなかった残りの 3 分の 1 のデータと，他のタイヤ 3 種のすべてのデータをテスト用とする．これを 4 度繰り返して，すべてのタイヤ種が学習データとなるように認識テストを行った．学習に際し，5.3.1 節と同様に，正例数を n_1 ，負例数を n_2 とした時，正例に対する識別関数の値を n_2/n_1 ，負例に対しては -1 となるように学習した．図 52～図 55 はそれぞれ，

図 52: タイヤ A のデータを学習用に使用したとき

図 53: タイヤ B のデータを学習用に使用したとき

図 54: タイヤ C のデータを学習用に使用したとき

図 55: タイヤ D のデータを学習用に使用したとき

の正答率を示したものである．これらの結果が示すように，今回使用した 4 種のタイヤのどれを学習用に使用しても，概 90% 以上で判別できており，本研究の目的の一つであるタイヤサイズ変更に対するロバスト性の高さが示された．特徴量による精度の違いについて，図 54 に示すタイヤ C で学習した時のタイヤ B の精度，および図 55 に示すタイヤ D で学習した時のタイヤ B の精度において，特徴量を LPC ケプストラム係数とした時の正答率がやや低い，それ以外の条件については特徴量違いによる精度の差は小さい．

より詳細に試験結果を分析するため，走行条件毎の正答率を調べた．表 22 は特徴量をバンドパスフィルタ透過波のパワー値の平均とし，タイヤ A で学習した時の正答率を速度・路面状態毎に示したものである．タイヤ B およびタイヤ C の凍結で精度が低い他は，90% 以上の高精度で判別できている．このような傾向は他のタイヤで学習した条件でも同様であり，表 23 に示すタイヤ B で学習した時のタイヤ A の凍結 30km/h とタイヤ D の凍結，表 24 に示すタイヤ C で学習した時ではタイヤ A，タイヤ B およびタイヤ D の凍結，また表 25 に示すタイヤ D で学習した時のタイヤ A，タイヤ B およびタイヤ C の凍結以外は，高精度で判別できている．一方，特徴量を LPC ケプストラム係数とした場合では，上述のよう

に精度低下がみられたタイヤ A で学習した時のタイヤ B およびタイヤ C の凍結の精度は概ね良好である（表 26）。また表 27 に示すように、タイヤ B で学習した場合においても、タイヤ A とタイヤ D の凍結 30km/h の精度は、十分とは言えないが表 23 に示すバンドパスフィルタを用いた場合より高くなっている。表 28 に示すタイヤ C で学習した時のタイヤ A およびタイヤ B の凍結や、表 29 に示すタイヤ D で学習した時のタイヤ A の凍結の精度も同様である。他方、タイヤ A で学習した時のタイヤ C の高速域の圧雪（表 26）や、タイヤ C で学習した時のタイヤ B の低速域の圧雪（表 28）ではバンドパスフィルタを用いた場合より精度が低い。このように、精度を条件毎に詳細に調べた結果、バンドパスフィルタ透過波のパワー値の平均を特徴量とした場合、ドライアスファルト、ウェットアスファルト、圧雪の判別には有効であり、LPC ケプストラム係数を特徴量とした場合では凍結の精度が改善された。つまり特徴量ごとに高精度に判別できる条件が異なっていることがわかった。表 30 から表 33 ではバンドパスフィルタを用いて特徴量を算出した時のカーネル関数と LPC ケプストラム係数を特徴量としたときのカーネル関数の和をグラム行列とした場合の各条件での精度を示している。表 31 に示すタイヤ B で学習した時のタイヤ A の凍結の精度は、特徴量をバンドパスフィルタとしたときの精度は低かったが、高精度に判別できるようになった。また表 32 に示すタイヤ C で学習した時のタイヤ B の低速域の圧雪は、特徴量を LPC ケプストラム係数としたとき精度が低かったが、同様に高精度に判別できるようになった。これは特徴量ごとに異なる得手、不得手な条件を互いに補完しあったことを示唆している。しかし、表 32 に示すタイヤ C で学習した時のタイヤ D の凍結など、改善が見られない条件があり、全ての条件で実用的な精度で判別できるまでには至っていない。

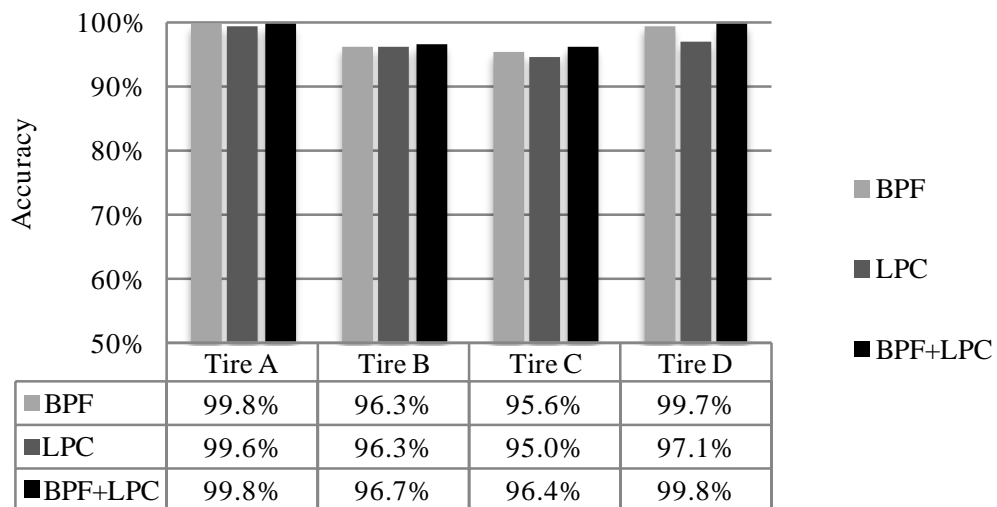
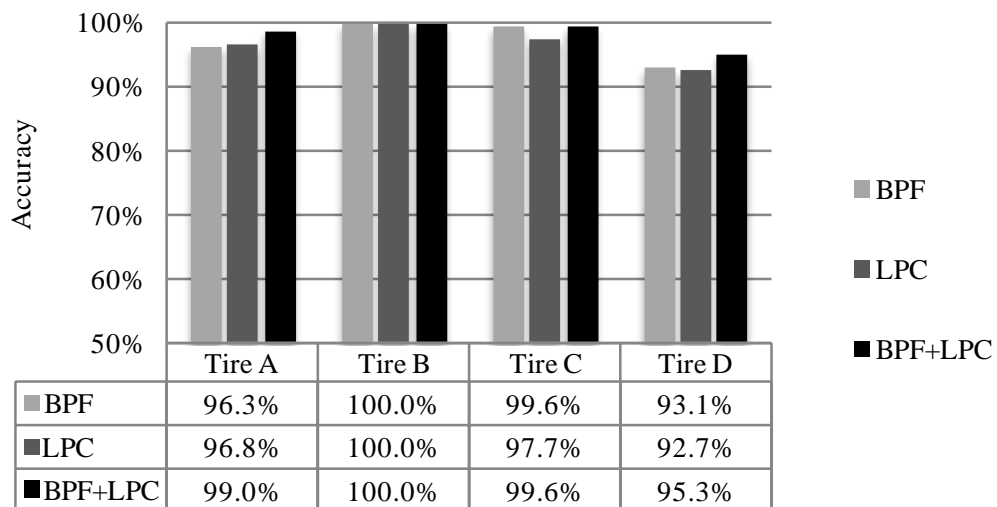


図 52 タイヤ A のデータを学習用に使用したときの精度



f

図 53 タイヤ B のデータを学習用に使用したときの精度

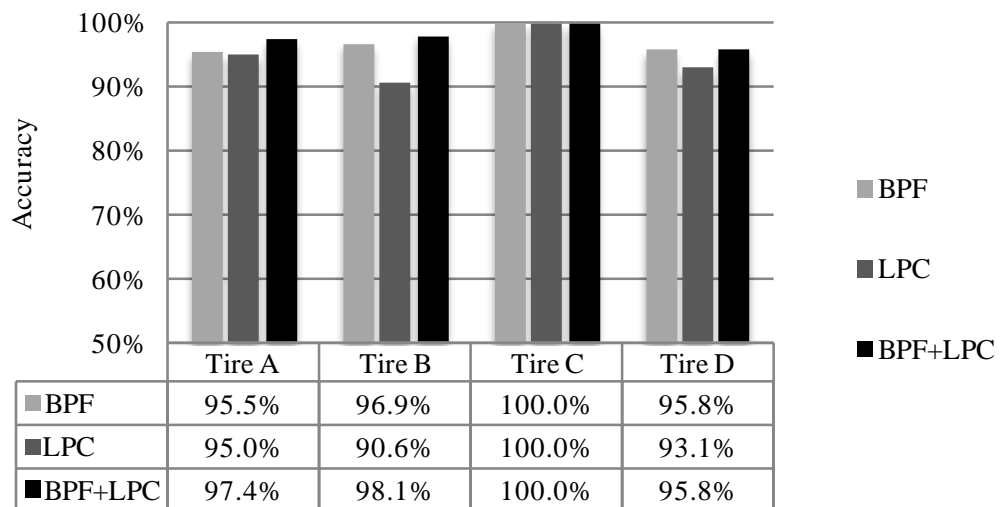


図 54 タイヤ C のデータを学習用に使用したときの精度

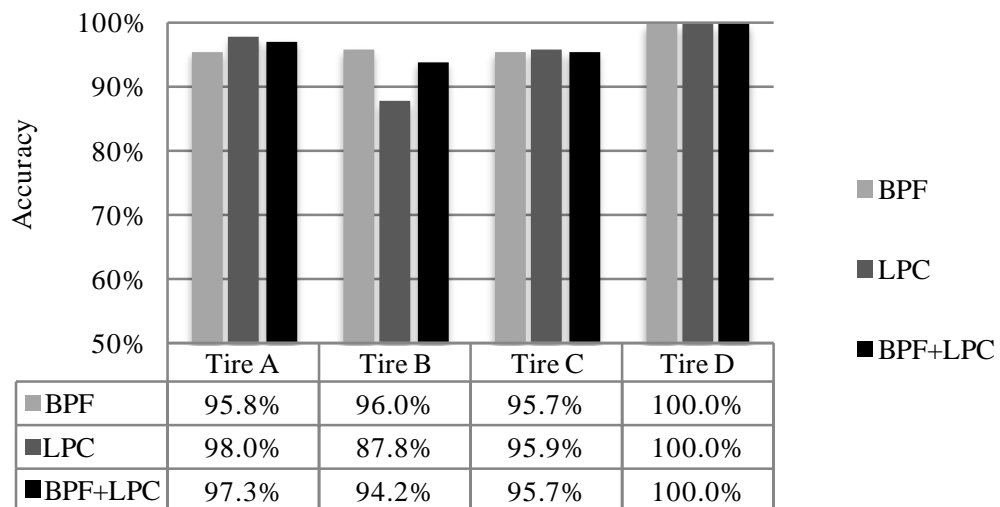


図 55 タイヤ D のデータを学習用に使用したときの精度

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	98.6%	100.0%	100.0%	100.0%	98.3%
wet	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
snow	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	-
ice	100.0%	100.0%	-	-	-	-	-

(a) TireA

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	99.5%	100.0%	100.0%	100.0%
wet	100.0%	98.5%	100.0%	100.0%	100.0%	100.0%	98.6%
snow	100.0%	100.0%	99.6%	100.0%	100.0%	98.5%	-
ice	5.0%	10.0%	-	-	-	-	-

(b) TireB

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
wet	100.0%	100.0%	100.0%	100.0%	98.5%	98.5%	98.4%
snow	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	-
ice	0.0%	0.0%	-	-	-	-	-

(c) TireC

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	99.5%	100.0%	100.0%	100.0%	100.0%	98.8%
wet	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
snow	100.0%	99.5%	100.0%	100.0%	100.0%	100.0%	-
ice	92.4%	98.5%	-	-	-	-	-

(d) TireD

表 22 TireA を学習データとした時の速度・路面状態毎の精度

特徴量：バンドパスフィルタ透過波のパワー値の平均値

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	99.5%	99.5%	99.5%	98.7%	95.4%
wet	92.4%	97.2%	95.7%	100.0%	98.4%	95.5%	100.0%
snow	100.0%	97.3%	100.0%	100.0%	100.0%	100.0%	-
ice	0.0%	85.9%	-	-	-	-	-

(a) TireA

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
wet	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
snow	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	-
ice	100.0%	100.0%	-	-	-	-	-

(b) TireB

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
wet	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
snow	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	-
ice	81.8%	98.5%	-	-	-	-	-

(c) TireC

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	99.5%	100.0%	100.0%	100.0%	98.9%	97.5%
wet	54.7%	100.0%	94.2%	100.0%	98.5%	95.5%	98.6%
snow	100.0%	77.0%	100.0%	100.0%	100.0%	100.0%	-
ice	0.0%	0.0%	-	-	-	-	-

(d) TireD

表 23 TireB を学習データとした時の速度・路面状態毎の精度

特徴量：バンドパスフィルタ透過波のパワー値の平均値

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	99.5%	100.0%	100.0%	99.3%	97.1%
wet	98.5%	98.6%	95.7%	100.0%	98.4%	94.0%	100.0%
snow	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	-
ice	0.0%	25.4%	-	-	-	-	-

(a) TireA

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	99.5%	100.0%	100.0%	100.0%
wet	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	98.6%
snow	100.0%	100.0%	100.0%	100.0%	100.0%	98.0%	-
ice	0.0%	41.7%	-	-	-	-	-

(b) TireB

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
wet	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
snow	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	-
ice	100.0%	100.0%	-	-	-	-	-

(c) TireC

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	99.5%	100.0%	100.0%	100.0%	100.0%	98.8%
wet	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
snow	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	-
ice	0.0%	0.0%	-	-	-	-	-

(d) TireD

表 24 TireC を学習データとした時の速度・路面状態毎の精度

特徴量：バンドパスフィルタ透過波のパワー値の平均値

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	99.5%	100.0%	100.0%	100.0%	98.3%
wet	98.5%	98.6%	95.7%	100.0%	98.4%	92.5%	100.0%
snow	100.0%	100.0%	100.0%	100.0%	100.0%	98.8%	-
ice	37.0%	0.0%	-	-	-	-	-

(a) TireA

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	99.5%	100.0%	100.0%	100.0%
wet	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	98.6%
snow	100.0%	100.0%	99.6%	100.0%	100.0%	97.0%	-
ice	0.0%	0.0%	-	-	-	-	-

(b) TireB

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
wet	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
snow	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	-
ice	0.0%	0.0%	-	-	-	-	-

(c) TireC

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
wet	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
snow	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	-
ice	100.0%	100.0%	-	-	-	-	-

(d) TireD

表 25 TireD を学習データとした時の速度・路面状態毎の精度

特徴量：バンドパスフィルタ透過波のパワー値の平均値

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	98.6%	98.6%	100.0%	100.0%	100.0%	98.3%
wet	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	93.8%
snow	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	-
ice	100.0%	100.0%	-	-	-	-	-

(a) TireA

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	98.6%	100.0%	98.9%	100.0%
wet	86.6%	69.1%	96.0%	100.0%	100.0%	98.7%	56.8%
snow	94.2%	96.8%	96.7%	99.5%	100.0%	95.5%	-
ice	78.3%	100.0%	-	-	-	-	-

(b) TireB

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	99.5%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
wet	98.6%	93.1%	85.5%	76.0%	57.4%	61.2%	24.2%
snow	99.4%	100.0%	100.0%	100.0%	100.0%	100.0%	-
ice	98.5%	75.8%	-	-	-	-	-

(c) TireC

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	99.1%	100.0%	100.0%	100.0%	99.5%	98.8%
wet	100.0%	98.6%	94.2%	98.5%	97.1%	94.0%	58.0%
snow	99.2%	100.0%	100.0%	100.0%	100.0%	97.5%	-
ice	100.0%	37.9%	-	-	-	-	-

(d) TireD

表 26 TireA を学習データとした時の速度・路面状態毎の精度

特徴量：LPC ケプストラム係数

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	97.8%	98.0%	97.1%
wet	100.0%	98.6%	100.0%	98.5%	98.4%	88.1%	100.0%
snow	98.3%	98.2%	97.9%	98.6%	98.9%	99.4%	-
ice	49.3%	66.2%	-	-	-	-	-

(a) TireA

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
wet	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
snow	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	-
ice	100.0%	100.0%	-	-	-	-	-

(b) TireB

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
wet	96.8%	95.5%	100.0%	100.0%	92.8%	91.7%	97.2%
snow	88.6%	96.4%	96.4%	100.0%	99.4%	95.9%	-
ice	98.5%	84.8%	-	-	-	-	-

(c) TireC

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	99.5%	100.0%	100.0%	100.0%	99.5%	100.0%
wet	100.0%	98.6%	81.2%	100.0%	100.0%	100.0%	100.0%
snow	88.3%	93.4%	89.8%	91.7%	94.2%	78.7%	-
ice	71.2%	1.5%	-	-	-	-	-

(d) TireD

表 27 TireB を学習データとした時の速度・路面状態毎の精度

特徴量：LPC ケプストラム係数

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	99.5%	96.3%	91.9%	92.4%	86.3%	90.1%	89.7%
wet	100.0%	98.6%	100.0%	100.0%	100.0%	94.0%	100.0%
snow	97.8%	99.1%	100.0%	99.1%	96.8%	97.0%	-
ice	64.4%	91.5%	-	-	-	-	-

(a) TireA

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	99.5%	99.5%	99.5%	100.0%	100.0%	100.0%
wet	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
snow	17.5%	43.9%	94.6%	99.5%	100.0%	90.4%	-
ice	96.8%	100.0%	-	-	-	-	-

(b) TireB

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
wet	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
snow	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	-
ice	100.0%	100.0%	-	-	-	-	-

(c) TireC

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	71.6%	93.6%	96.5%	98.5%	99.0%	99.5%	96.9%
wet	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
snow	100.0%	100.0%	100.0%	100.0%	99.7%	93.9%	-
ice	6.1%	9.1%	-	-	-	-	-

(d) TireD

表 28 TireC を学習データとした時の速度・路面状態毎の精度

特徴量：LPC ケプストラム係数

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	99.1%	99.1%	100.0%	100.0%	100.0%	98.9%
wet	97.0%	98.6%	100.0%	98.5%	96.7%	86.6%	98.0%
snow	100.0%	100.0%	100.0%	100.0%	100.0%	98.2%	-
ice	89.0%	59.2%	-	-	-	-	-

(a) TireA

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	99.0%	98.1%	95.0%	98.9%	100.0%
wet	100.0%	100.0%	89.9%	85.3%	75.0%	95.5%	95.9%
snow	54.5%	50.2%	93.8%	100.0%	100.0%	94.4%	-
ice	4.8%	1.7%	-	-	-	-	-

(b) TireB

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	100.0%	98.9%	100.0%
wet	98.5%	97.1%	97.3%	95.7%	95.8%	98.6%	100.0%
snow	98.7%	98.4%	100.0%	100.0%	100.0%	100.0%	-
ice	18.2%	21.2%	-	-	-	-	-

(c) TireC

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
wet	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
snow	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	-
ice	100.0%	100.0%	-	-	-	-	-

(d) TireD

表 29 TireD を学習データとした時の速度・路面状態毎の精度

特徴量：LPC ケプストラム係数

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	98.6%	100.0%	100.0%	100.0%	98.3%
wet	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
snow	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	-
ice	100.0%	100.0%	-	-	-	-	-

(a) TireA

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	99.5%	100.0%	100.0%	100.0%
wet	100.0%	89.7%	98.7%	100.0%	100.0%	100.0%	91.9%
snow	100.0%	99.6%	97.1%	100.0%	100.0%	96.0%	-
ice	28.3%	48.3%	-	-	-	-	-

(b) TireB

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
wet	100.0%	100.0%	100.0%	100.0%	95.6%	98.5%	77.4%
snow	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	-
ice	56.1%	3.0%	-	-	-	-	-

(c) TireC

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	98.8%
wet	100.0%	100.0%	100.0%	100.0%	100.0%	95.7%	100.0%
snow	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
ice	100.0%	100.0%	-	-	-	-	-

(d) TireD

表 30 TireA を学習データとした時の速度・路面状態毎の精度
特徴量：LPC ケプストラム係数＋バンドパスフィルタ透過波のパワー値の平均値

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	96.6%
wet	98.5%	98.6%	95.7%	100.0%	98.4%	94.0%	100.0%
snow	98.9%	95.0%	100.0%	100.0%	100.0%	100.0%	-
ice	94.5%	100.0%	-	-	-	-	-

(a) TireA

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
wet	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
snow	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	-
ice	100.0%	100.0%	-	-	-	-	-

(b) TireB

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
wet	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
snow	96.2%	97.2%	100.0%	100.0%	100.0%	100.0%	-
ice	100.0%	100.0%	-	-	-	-	-

(c) TireC

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	98.8%
wet	100.0%	100.0%	98.6%	100.0%	100.0%	98.5%	98.6%
snow	92.5%	73.2%	99.2%	100.0%	100.0%	100.0%	-
ice	59.1%	7.6%	-	-	-	-	-

(d) TireD

表 31 TireB を学習データとした時の速度・路面状態毎の精度
特徴量：LPC ケプストラム係数＋バンドパスフィルタ透過波のパワー値の平均値

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	99.5%	100.0%	100.0%	100.0%	97.7%
wet	100.0%	98.6%	97.1%	100.0%	98.4%	94.0%	100.0%
snow	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	-
ice	8.2%	97.2%	-	-	-	-	-

(a) TireA

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
wet	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
snow	96.8%	98.8%	98.3%	100.0%	100.0%	95.5%	-
ice	50.0%	85.0%	-	-	-	-	-

(b) TireB

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
wet	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
snow	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	-
ice	100.0%	100.0%	-	-	-	-	-

(c) TireC

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	99.5%	100.0%	100.0%	100.0%	100.0%	98.8%
wet	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
snow	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	-
ice	0.0%	0.0%	-	-	-	-	-

(d) TireD

表 32 TireC を学習データとした時の速度・路面状態毎の精度
特徴量：LPC ケプストラム係数＋バンドパスフィルタ透過波のパワー値の平均値

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	99.5%	100.0%	100.0%	100.0%	98.3%
wet	98.5%	98.6%	95.7%	100.0%	98.4%	94.0%	100.0%
snow	100.0%	100.0%	100.0%	100.0%	100.0%	99.4%	-
ice	90.4%	12.7%	-	-	-	-	-

(a) TireA

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
wet	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
snow	80.5%	91.7%	97.1%	100.0%	100.0%	94.4%	-
ice	0.0%	0.0%	-	-	-	-	-

(b) TireB

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
wet	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
snow	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	-
ice	0.0%	0.0%	-	-	-	-	-

(c) TireC

	30km/h	40km/h	50km/h	60km/h	70km/h	80km/h	90km/h
dry	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
wet	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
snow	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%	-
ice	100.0%	100.0%	-	-	-	-	-

(d) TireD

表 33 TireD を学習データとした時の速度・路面状態毎の精度
特徴量：LPC ケプストラム係数＋バンドパスフィルタ透過波のパワー値の平均値

5.4 この章の考察とまとめ

5.3.1 で示した結果から，本章で詳説した GA カーネルを用いた路面状態判別方法では，今回特徴量として採用したバンドパスフィルタの透過波のパワー値の平均および LPC ケプストラム係数のどちらを用いても，精度は 90%以上で判別できしており，4.3.3 で示した HMM を用いた手法以上の高精度で路面状態判別が可能であることが示された．また 4.3.3 で示したように，本研究とは試験条件が異なるが，先行研究では，74%～82%の精度で路面状態を判別しており [16] [17] [18]，車輪速や接地長の情報なしに先行研究よりも高精度に路面状態を判別できることを示した．しかし精度を路面状態毎，速度毎に見てみると，多数の条件下では 80%以上の高い正答率で判別できていたが，一部正答率の低い条件があった．正答率が低い条件は主に低速の凍結路であった．正答率が低い条件として，バンドパスフィルタ透過波の平均値を用いたカーネル関数と LPC ケプストラム係数を用いたカーネル関数の和をカーネル行列として計算したモデルにおける，タイヤ B およびタイヤ C の凍結路の判別結果を図 56，図 57 に示す．誤った判別は全て圧雪への判別であった．本研究では路面状態を 4 種に判別することを考えてきたが，この結果は，圧雪と凍結を合わせて低 μ 路面とするのであれば高い精度で判別できることを示している．表 34 に路面状態と路面摩擦係数の関係を示した [88] [89]．ドライアスファルト，ウェットアスファルト，低 μ 路面というカテゴリーの仕方は路面摩擦係数という指標で見ても自然であり，上記のように路面状態の分類数を 4 から 3 に減らしても，潜在的な路面状態の危険性を示す上で有効であると考える．

路面状態	摩擦係数
ドライアスファルト	0.7～0.9
ウェットアスファルト	0.45～0.6
圧雪	0.2～0.4
凍結	0.1～0.2

表 34 路面状態と路面タイヤ間摩擦係数の関係

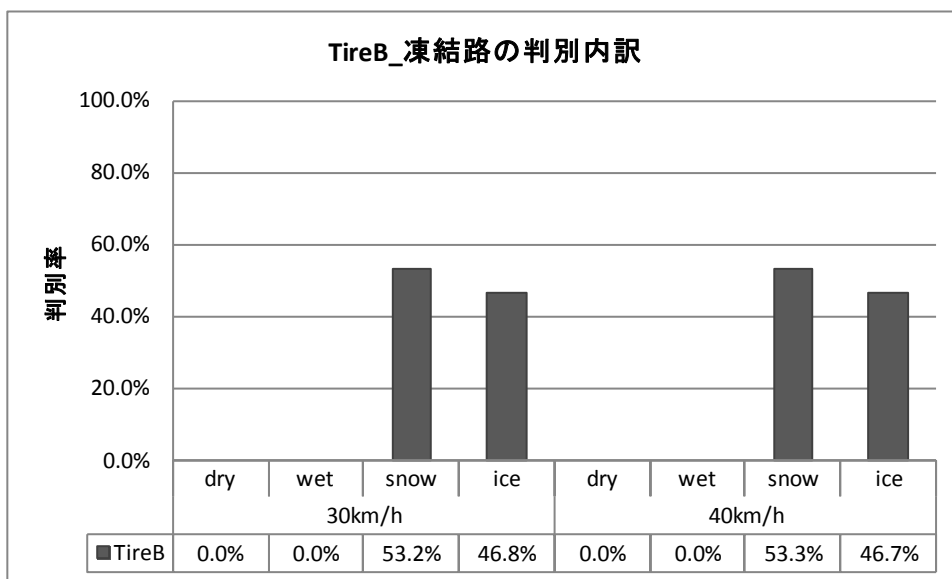


図 56 タイヤ B の凍結路の判別結果

特徴量：LPC ケプストラム係数＋バンドパスフィルタ透過波のパワー値の平均値

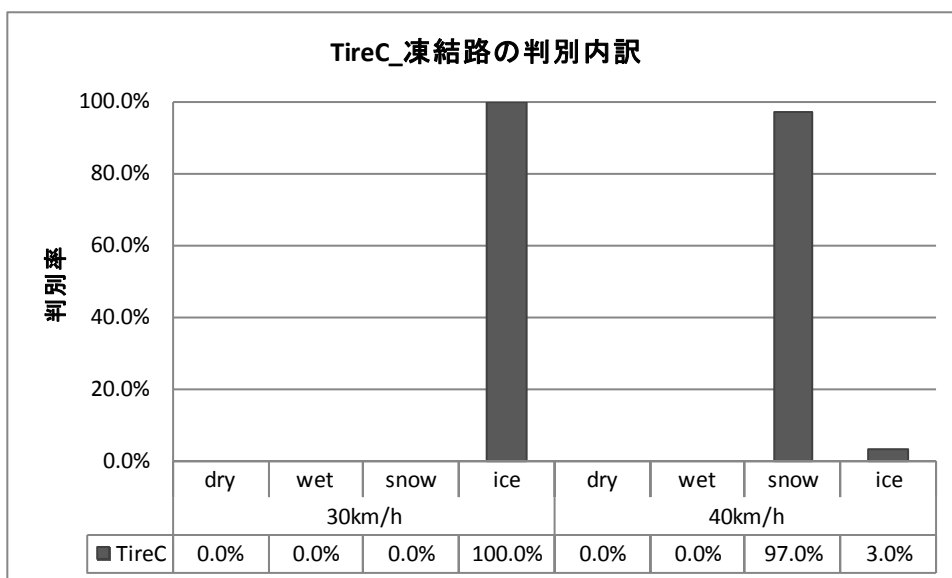


図 57 タイヤ C の凍結路の判別結果

特徴量：LPC ケプストラム係数＋バンドパスフィルタ透過波のパワー値の平均値

5.3.2 ではタイヤサイズ変更に対するロバスト性の評価を行った．今回使用した 4 種のタイヤのどれを学習用に使用しても，概 90%以上で判別できている．4.3.3 および 4.3.4 で説明した先行研究や HMM に基づく手法よりも高精度であり，本研

究の目的の一つであるタイヤサイズ変更に対するロバスト性の高さを示した。しかし各路面状態・速度毎の正答率を調べたところ、特に凍結路で精度の低い条件があった。LPC ケプストラム係数とバンドパスフィルタ透過波のパワー値の平均値の両者を特徴量とした条件が最も精度が高いが、それでも一部条件での低い精度を是正できなかった。しかし表 35 に示すように、正答率の低い条件が多かった凍結路において誤判別した先はほとんどが圧雪であり、つまり 3 分類であれば、本研究の目的であるタイヤ振動情報のみから、タイヤサイズ変更に対し頑健な路面状態判別が高精度に行えることが示された。

路面状態	学習データ	テストデータ	判別結果			
			DRY	WET	SNOW	ICE
凍結	タイヤ A	タイヤ A	0.0%	0.0%	0.0%	100.0%
		タイヤ B	0.0%	0.0%	62.3%	37.7%
		タイヤ C	0.0%	0.0%	70.5%	29.5%
		タイヤ D	0.0%	0.0%	0.0%	100.0%
	タイヤ B	タイヤ A	1.4%	0.0%	1.4%	97.2%
		タイヤ B	0.0%	0.0%	0.0%	100.0%
		タイヤ C	0.0%	0.0%	0.0%	100.0%
		タイヤ D	39.4%	0.0%	27.3%	33.3%
	タイヤ C	タイヤ A	11.8%	0.0%	36.1%	52.1%
		タイヤ B	0.0%	0.0%	32.8%	67.2%
		タイヤ C	0.0%	0.0%	0.0%	100.0%
		タイヤ D	0.0%	0.0%	100.0%	0.0%
	タイヤ D	タイヤ A	0.0%	0.0%	47.9%	52.1%
		タイヤ B	0.0%	0.0%	100.0%	0.0%
		タイヤ C	0.0%	0.0%	100.0%	0.0%
		タイヤ D	0.0%	0.0%	0.0%	100.0%

表 35 各条件における凍結路での判別結果内訳

特徴量：LPC ケプストラム係数＋バンドパスフィルタ透過波のパワー値の平均値

第 6 章 結論

本研究ではタイヤ振動情報のみから，HMM や GA カーネルといった時間整合アルゴリズムを用いて，路面状態を判別する手法について述べた．

タイヤ振動は，タイヤが高速で転動するときの動的な挙動を反映して特徴が時間的に変化し，且つ車輪速変化に伴って時間伸縮するという非定常性の強い波形を示す．我々は先行研究 [16] [17] [18]においてタイヤの動的挙動に関する経験的な知識に基づいて窓掛けを行い，別途車輪速を計測してその窓幅を調整することによって，そのような時間伸縮に対応した解析法を開発した．様々な条件での計測・解析を行う過程でタイヤ振動の特徴が路面状態によって変化することを見出し，その逆問題として，タイヤ振動波形から路面状態を判別するアルゴリズムを開発した．しかし先行研究におけるシステムでは車輪速やマイクなど複数のセンサや情報が必要であり，システムが複雑化していること，および 1 つのサイズ，1 つのトレッドパターン（溝のデザイン）にしか対応できないため，それぞれ個別に対応せざるを得ず，開発コストの増大を招いていた．そこで本研究では，統計的解析手法に基づく時間整合アルゴリズムを用いて，タイヤ振動情報のみからタイヤサイズ変更に対するロバスト性の高い路面状態判別技術を提案した．

一つ目の手法として，HMM を用いて接地面付近の波形を路面状態毎にモデル化し，未知データに対する尤度を比較して路面状態を判別する方法を提案した．判別精度は特徴量を LPC ケプストラム係数とした時，6 状態モデルでは 84.6%~92.6%，7 状態モデルでは 87.2%~92.0% の正答率で路面状態を判別できおり，車輪速や接地長の情報なしに先行研究よりも高精度に路面状態を判別できることを示した．二つ目の手法として，GA カーネルによってタイヤ振動の時系列を比較し SVM を用いて路面状態を判別する手法を提案した．大多数の条件下で 80%以上の高い正答率で判別できおり，先行研究 [16] [17] [18]や HMM を用いた手法よりも高精度であった．一部の凍結路のデータにおいて精度が低い条件があったが，そのほとんどは圧雪への誤判別によるもので，例えば圧雪と凍結を低 μ 路というカテゴリーにまとめれば，本研究の目的である，タイヤ振動情報のみからタイヤサイズ変更に対するロバスト性の高い路面判別が可能となる．

ここで HMM を用いた手法と GA カーネルを用いた手法の精度差について議論したい．生成モデルと識別モデル，あるいは識別関数のいずれの手法が良いかについては，機械学習の分野で関心が高く様々な議論がなされている [90] [91]．ラ

ベルがありデータが少数であるときには生成モデルの判別性能が高いことが報告されているが [92], 一般的には単純なクラス分類を考えた時, 識別モデルや識別関数による判別器は生成モデルよりも高い判別性能を持つことが知られている [93]. 本研究においては, 表 5 に示すようにデータ数は十分にあると考えられるので, この一般論が当てはまったと言える. 個別具体的には, 本研究では HMM を用いる手法において, 状態数を 5, 6, 7 状態に設定し, その中での状態遷移を考えたが, GA カーネルでは窓毎に類似度を測り比較しているので, 状態数という制約がなく柔軟性が高いと言える. 先行研究 [16] [17] [18] の検討から, タイヤ振動波形を, タイヤの動的挙動に基づく領域 (路面踏み込み, 接地, 蹴り出し等) に離散的に分割することが, モデルを構築する上で有利になると考えたが, 結果としては, GA カーネルを用いて最適パスの周辺も含めて連続的に類似度を評価するほうが本研究には適していた.

今後の課題として, GA カーネルは上記のように高精度に判別できる半面, 計算負荷が高く, 現状ではリアルタイム処理が難しい. アライメントを取る時のパスを制限し, 計算量の縮減や並列化することによって, 高速化することを目指す. 加えて, 本研究ではタイヤ振動の動的変化を捉えて路面状態を判別する問題を考えたが, 本研究で提案したタイヤ振動解析法を用いれば, タイヤ振動からタイヤー路面間の接地特性が評価できるようになると期待でき, 乗り心地や操縦安定性の評価への応用可能性があると考えている.

このように本論文では, タイヤにセンシング機能という新たな価値を付与することを可能にする振動解析手法を提案した.

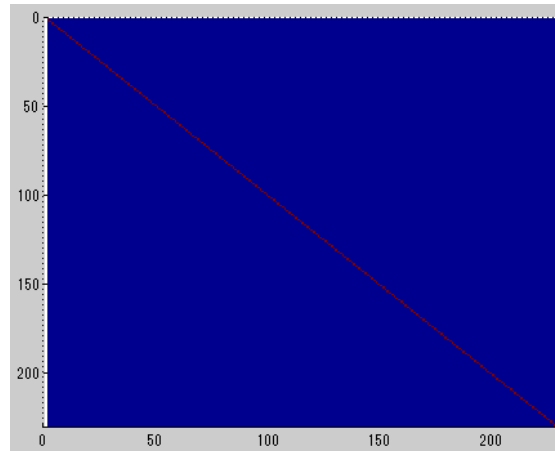
付録

ここでは，5章で述べた GA カーネルのチューニングパラメータ： σ と SVM のコストパラメータ： C の決定方法について説明する．両パラメータとも 4.3.1 節で示した tireA のデータを用いて 3 分割交差確認法で決定した．ただし，計算時間の観点から，表 5(a)に示した全データから，各条件毎に 15 点を選択して使用した． σ についてはグラム行列の比較から対角優位性を評価した結果も考慮した．

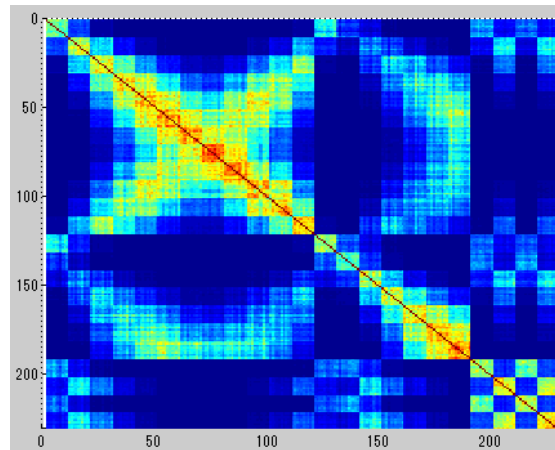
まず，GA カーネルのチューニングパラメータ： σ について，交差確認法で算出した精度を図 58 に示す．このときの SVM コストパラメータ： C はすべて 1 とした．この結果より特徴量を LPC ケプストラム係数とした時は $\sigma = 10$ ，バンドパスフィルタの透過波の平均値を用いた場合には $\sigma = 100$ とすることとした．また特徴量を LPC ケプストラム係数とした時の各 σ におけるグラム行列を図 59，特徴量をバンドパスフィルタの透過波の平均値とした時の各 σ におけるグラム行列を図 60 に示す．図 59 及び図 60 の縦横軸に対応するデータ番号とデータの取得条件の対応を表 36 に示す．グラム行列は 5-3-1 式，5-3-2 式，5-3-3 式によって規格化されている．特徴量を LPC ケプストラム係数とした時の $\sigma = 1$ ，およびバンドパスフィルタの透過波の平均値を用いた時の $\sigma = 10$ では対角優位性が強く，このことが精度低下の要因であると考えられる．また特徴量を LPC ケプストラム係数とした時の $\sigma = 100$ ，およびバンドパスフィルタの透過波の平均値を用いた時の $\sigma = 1000$ では他の路面条件との類似性が高いことが見て取れる．このことは，路面状態間差をうまく捉えられていないことを示唆しており，精度低下の要因であると考えられる．

	$\sigma = 1$	$\sigma = 10$	$\sigma = 100$	$\sigma = 1000$
LPC ケプストラム	43.7%	100%	38.7%	-
バンドパスフィルタ	-	42.9%	100%	73.9%

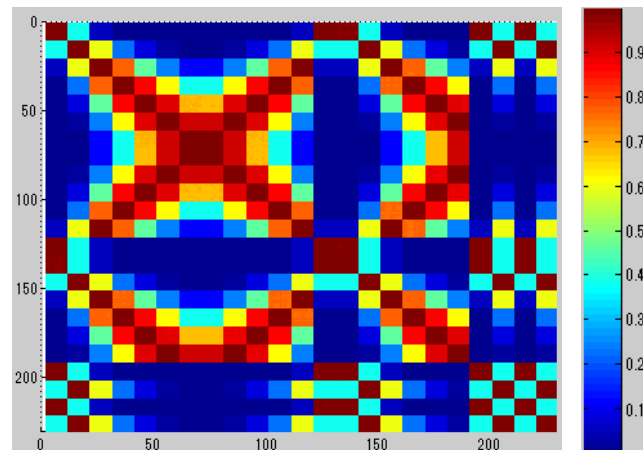
図 58 σ に関し交差確認法で求めた精度



(a) $\sigma = 1$

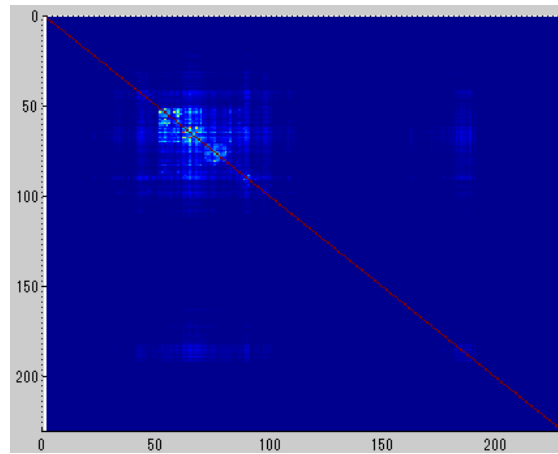


(b) $\sigma = 10$

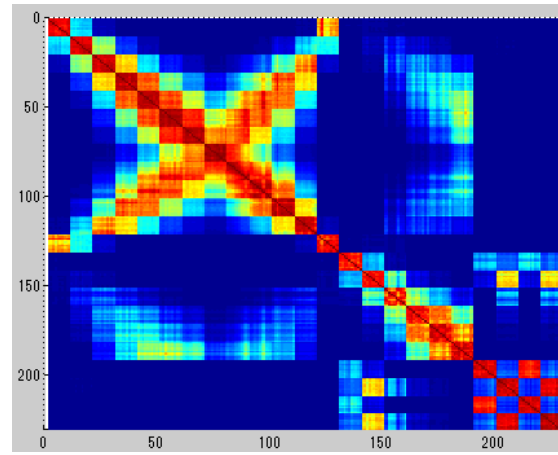


(c) $\sigma = 100$

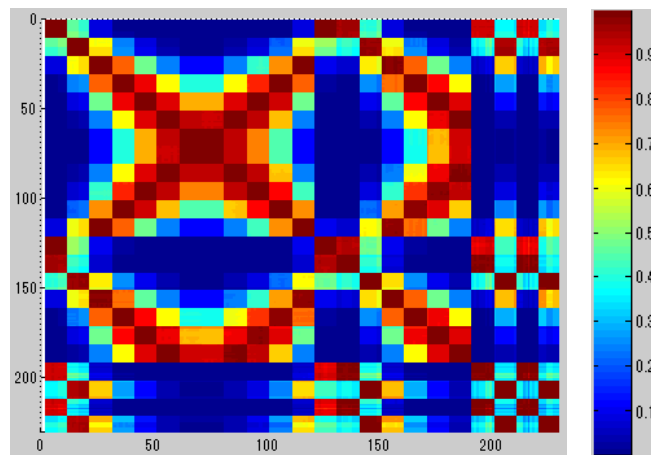
図 59 特徴量を LPC ケプストラム係数とした時の各 σ におけるグラム行列



(a) $\sigma = 10$



(b) $\sigma = 100$



(c) $\sigma = 1000$

図 60 特徴量をバンドパスフィルタ透過波の平均値とした時の各 σ における
グラム行列

路面状態	速度[km/h]	開始番号	終了番号
ドライ	30	1	10
	40	11	20
	50	21	30
	60	31	40
	70	41	50
	80	51	60
	90	61	70
ウェット	30	121	130
	40	111	120
	50	101	110
	60	91	100
	70	81	90
	80	71	80
圧雪	30	131	140
	40	141	150
	50	151	160
	60	161	170
	70	171	180
	80	181	190
凍結	30	191	200
		211	220
	40	201	210
		221	230

表 36 図 59 及び図 60 におけるデータ番号とデータ取得条件の対応

次に、SVM のコストパラメータ：C について、交差確認法で算出した精度を図 61 に示す。この結果から、特徴量を LPC ケプストラム係数とした時、および特徴量をバンドパスフィルタ透過波の平均値とした時共に、SVM のコストパラメータ：C を 1 とした。

	C=0.1	C=1	C=10
LPC ケプストラム	99.2%	100%	99.2%
バンドパスフィルタ	89.1%	100%	97.5%

図 61 C に関し交差確認法で求めた精度

謝辞

本研究は、著者が総合研究大学院大学複合科学研究科統計科学専攻在学中に、統計数理研究所 樋口知之教授の指導のもとに行ったものです。

樋口先生には本学入学前から研究の進め方など基礎からご指導いただきました。また入学後は社会人学生として研究時間が制約された中で効率的に進められるような研究環境を整えていただきました。心より感謝申し上げます。

論文審査を通して、貴重な御意見を下さった統計数理研究所の松井知子先生、吉田亮先生、三分一史和先生、東京工業大学の篠田浩一先生に感謝いたします。先生方のご意見は今後研究を進めるにあたって、大変参考になるものでした。

総合研究大学院大学での研究についてご理解いただき、このような機会を与えてくださった（株）ブリヂストンタイヤ研究本部および中央研究所の関係各位に感謝申し上げます。特に中島幸雄氏、門田邦信氏、森永啓詩氏に深く感謝いたします。

最後に、本研究を行うに当たり陰ながら支えてくれた妻の佳奈子、娘の紗衣と由莉に感謝いたします。

引用文献

- [1] 警察庁, “平成 23 年警察白書,” 2011.
- [2] 内閣府, “第 9 次交通安全基本計画,” 中央交通安全対策会議, 2011.
- [3] 国土交通省自動車交通局 先進安全自動車推進検討会, “第 4 期 ASV 推進計画成果報告会 (成果報告書),” 2011. [オンライン]. Available: http://www.mlit.go.jp/jidosha/anzen/01asv/resource/data/asv4pamphlet_seika.pdf.
- [4] C.-S. Liu , H. Peng, “Road Friction Coefficient Estimation For Vehicle Path Prediction,” *Vehicle System Dynamics*, Vol.25, pp.413-425, 1996.
- [5] F. Gustafsson, “Slip-based tire-road friction estimation,” *Automatica*, Volume 33, No.6, pp. 1087-1099, 1997.
- [6] U. Eichhorn , J. Roth, “Prediction And Monitoring of Tyre/Road Friction,” *Proceedings FISITA*, 1992.
- [7] J. Dakhlallah, S. Glaser, S. Mammar , Y. Sebsadji, “Tire-road forces estimation using extended Kalman filter and sideslip angle evaluation,” *American Control Conference*, pp. 4597 - 4602, 2008.
- [8] NHTSA, “National Highway Traffic Safety Administration,” [オンライン]. Available: <http://www.nhtsa.gov/cars/rules/rulings/tirepresfinal/>.
- [9] UNECE, “United Nations Economic Commission for Europe,” [オンライン]. Available: <http://www.unece.org/fileadmin/DAM/trans/main/wp29/wp29regs/r064r1e.pdf>.
- [10] APOLLO Project, "Final Report Including Technical Implementation Plan," 2005. [Online]. Available: http://virtual.vtt.fi/apollo/deliverables/apollo_final%20report.pdf.
- [11] R. Matsuzaki , A. Todoroki, “Wireless monitoring of automobile tires for intelligent tires,” *Sensors*, pp. vol.8(12), pp. 8123-8138, 2008.
- [12] T. Becherer, “The sidewall torsion sensor system,” *VDI-Fortschrittberichte*.
- [13] F. Cheli, G. Audisio, M. Brusarosco, F. Mancosu, D. Cavaglieri , S. Melzi, “Cyber Tyre: A Novel Sensor to Improve Vehicle's Safety,” *SAE Technical Paper* , 2011.

- [14] A. J. Tuononen, "Optical position detection to measure tyre carcass deflections," Taylor & Francis Vehicle System Dynamics Vol. 46, No. 6., 2008.
- [15] A. Pohl, R. Steindl, L. Reindl, "The intelligent tire utilizing SAW sensors - measurement of tire friction," IEEE Trans. Instrument. Measure, 1999.
- [16] H. Morinaga, Y. Wakao, Y. Hanatsuka and A. Kobayakawa, "The Possibility of Intelligent Tire (Technology of Contact Area Information Sensing)," *FISITA2006 Transactions*, vol. F2006V104, 2006.
- [17] H. Morinaga, Y. Hanatsuka and Y. Wakao, "Sensing Technology Tire System for Road Surface Condition Judgment," *FISITA2010 Transactions*, vol. F2010E010, 2010.
- [18] 花塚 泰史, 森永 啓詩, 若尾 泰道, "インテリジェントタイヤによる路面状態判別," 雪氷研究大会講演要旨集, 2010.
- [19] 酒井秀男, タイヤ工学, グランプリ出版.
- [20] ブリヂストン, "自動車用タイヤの基礎と実際," 東京電機大学出版局, 2008.
- [21] B. Bogert, M. Healy, J. Tukey, "The quefrency analysis of time series for echoes," *Proceedings of the symposium on Time Series Analysis*, 1963.
- [22] J. D. Markel, A. H. Gray Jr, *Linear Prediction of Speech*, New York: Springer-Verlag, 1976.
- [23] S. S. Stevens, J. Volkman and E. Newman, "A Scale for the Measurement of the Psychological Magnitude Pitch," *Journal of the Acoustical Society of America* 8(3), 1937.
- [24] S. Young, G. Evermann, M. Gales, T. Hain, D. Kershaw, X. (Liu, G. Moore, J. Odell, D. Ollason, D. Povey, V. Valtchev, P. Woodland, *The HTK Book*, ver.3.4, Entropic Cambridge Research Laboratory, 2006.
- [25] V. A. Petrushin, "Hidden Markov Models: Fundamentals and Applications," *Online Symposium for Electronics Engineer*, <http://www.techonline.com/osee/>, 2000.
- [26] C. M. Bishop, *Pattern Recognition and Machine Learning*, Springer, 2006.
- [27] B. H. Juang and L. R. Rabiner, "Hidden Markov Models for Speech Recognition,"

Technometrics, vol. 33, no. 3, pp. 251-272, 1991.

- [28] C. D. Manning , H. Schütze, “Foundations of Statistical Natural Language Processing,” *MIT Press*, May 1999.
- [29] L. R. Rabiner, “A tutorial on hidden Markov models and selected applications in speech recognition,” *Proceedings of the IEEE*, Volume: 77 , Issue: 2 , 1989.
- [30] L. Bahl, P. Brown, P. de Souza , R. Mercer, “Maximum mutual information estimation of hidden Markov model parameters for speech recognition,” *Acoustics, Speech, and Signal Processing, IEEE International Conference on ICASSP '86*, 1986.
- [31] H. BUNKE, M. ROTH , E. G. SCHUKAT-TALAMAZZINI, “OFF-LINE CURSIVE HANDWRITING RECOGNITION USING HIDDEN MARKOV MODELS,” *Pattern Recognition*, Vol. 28, No. 9, 1995.
- [32] J. Makhoul, T. Starner, R. Schwartz , G. Chou, “On-Line Cursive Handwriting Recognition Using Hidden Markov Models and Statistical Grammars,” *Proceedings of a Workshop HUMAN LANGUAGE TECHNOLOGY*, 1994.
- [33] T. Yoda, Y. Totoki, M. Ishikawa, K. Asai , K. Nakai, “Automatic extraction of motifs represented in the hidden Markov model from a number of DNA sequences,” *Bioinformatics*, 1998.
- [34] D. Kulp, D. Haussler, M. G. Reese , F. H. Eeckman, “A Generalized Hidden Markov Model for the Recognition of Human Genes in DNA,” *ISMB-96 Proceedings*, 1996.
- [35] J. G. McLachlan , E. K. Basford, “Mixture Models,” *Inference and Applications to Clustering*, New York: Marcel Dekker, 1988.
- [36] G. J. McLachlan , D. Peel, “Finite Mixture Models,” *Wiley Series in Probability & Mathematical Statistics*, 2000.
- [37] J. A. Viterbi, “Error bounds for convolutional codes and an asymptotically optimum decoding algorithm,” *IEEE Transactions on Information Theory*, IT-13, 1967.
- [38] 福水健次, カーネル法入門, 朝倉書店, 2010.

- [39] B. Schölkopf, A. Smola , K.-R. Müller, “Nonlinear Component Analysis as a Kernel Eigenvalue Problem,” *Neural computation*, Vol. 10, No. 5, pp. 1299-1319, 1998.
- [40] F. R. Bach , M. I. Jordan, “Kernel Independent Component Analysis,” *Journal of Machine Learning Research* vol. 3, pp. 1-48, 2002.
- [41] B. E. Boser, I. M. Guyon , V. N. Vapnik, “A training algorithm for optimal margin classifiers,” *5th Annual ACM Workshop on COLT*, pp. 144 - 152, 1992.
- [42] C. Corinna , V. Vapnik, “Support-Vector Networks,” *Machine Learning*, 1995.
- [43] N. Cristianini and J. S-Taylor, "An Introduction to Support Vector Machines and other kernel-based learning methods," *Cambridge University Press*, 2000.
- [44] O. Chapelle, P. Haffner , V. N. Vapnik, “ Support vector machine for histogram-based image classification,” *IEEE Trans. NEURAL NETWORKS*, vol. 10, No. 5, 1999.
- [45] K. S. Goh, E. Chang , K. T. Cheng, “SVM binary classifier ensembles for image classification,” *Proceedings of ICIKM '01*, 2001.
- [46] G. M. Foody , A. Mathur, “A relative evaluation of multiclass image classification by support vector machines,” *IEEE Geoscience and Remote Sensing*, vol.42, no.6, pp.1335-1343, 2004.
- [47] R. Chaves, J. Ramírez, J. M. Górriz, M. López, D. Salas-Gonzalez, I. Álvarez , F. Segovia, “SVM-based computer-aided diagnosis of the Alzheimer’ s disease using t-test NMSE feature selection with feature correlation weighting,” *Neuroscience Letters*, Volume 461 (3) , pp. 293-297, 2009.
- [48] C. Bahlmann, B. Haasdonk , H. Burkhardt, “On-line Handwriting Recognition with Support Vector Machines-A Kernel Approach,” *Proceedings of the IWFHR*, pp. 49-54, 2002.
- [49] T. Joachims, “Text Categorization with Support Vector. Machines: Learning with Many Relevant Features,” *Proceedings of the ECML*, pp.137-142, 1998.
- [50] A. Basu, C. Walters , M. Shepherd, “ Support vector machines for text categorization,” *Proceedings of the 36th HICSS*, 2003.

- [51] M. M. Adankon , M. Cheriet, “Model selection for the LS-SVM. Application to handwriting recognition,” *Pattern Recognition*, Volume 42, No. 12, Pages 3264-3270, 2009.
- [52] W. M. Campbell, J. P. Campbell, D. A. Reynolds, E. Singer , P. A. Torres-Carrasquillo, “ Supportvectormachines for speaker and language recognition,” *The speaker and Language Recognition Workshop* , Volume 20, Issues 2-3, pp. 210-229, 2006.
- [53] M. Senoussaoui, P. Kenny, N. Dehak , P. Dumouchel, “An i-vector Extractor Suitable for Speaker Recognition with both Microphone and Telephone Speech,” *Proceedings of Odyssey-2010*, paper 006, 2010.
- [54] N. D. Smith , M. F. Gales, “Speech recognition using SVMs,” *Advances in Neural Information Processing Systems*, 2001.
- [55] W. M. Campbell, D. Sturim, D. A. Reynolds , A. Solomonoff, “SVM based speaker verification using a GMM supervector kernel andNAP variability compensation,” *Proceedings of the ICASSP*, 2006.
- [56] V. Wan , S. Renals, “Speaker verification using sequence discriminant support vector machines,” *IEEE Transactions Speech andAudio Processing*, 2004.
- [57] K. Kim, “Financial time series forecasting using supportvector machines,” *Neurocomputing*, vol. 55, pp. 307-319, 2003.
- [58] K. R. Müller, A. J. Smola, G. Rätsch, B. Schölkopf, J. Kohlmorgen , V. Vapnik, “Predicting Time Series with Support Vector Machines,” *ICANN'97*, Springer Lec. Notes Comput.Sci, vol.1327, pp.999-1004, 1997.
- [59] S. Rüping, “SVM Kernels for Time Series Analysis,” *Proceedings of the LLWA* 01, 2001.
- [60] K. Borgwardt, S. N. Vishwanathan , H. Kriegel, “Class Prediction from Time Series Gene Expression Profiles Using Dynamical Systems Kernels,” *Proceedings of the Pacific Symposium of Biocomputing*, 2006.
- [61] J. Mager, U. Paasche , B. Sick, “Forecasting financial time series with support vector machines based on dynamic kernels,” *IEEE SMCia '08 Soft Computing in*

Industrial Applications, 2008.

- [62] M. Davy, A. Gretton, A. Doucet , P. W. Rayner, “Optimized Support Vector Machines for Nonstationary Signal Classification,” *IEEE Signal Processing Letters*, vol. 9, No. 12, pp.442-446, 2002.
- [63] P. Honein, C. Richard , P. Flandrin, “Time-frequency learning machines,” *IEEE Transactions on Signal Processing*, vol. 55 , No. 7 pp.3930 - 3936, 2007.
- [64] E. S. Fonseca, R. C. Guido, P. R. Scalassara, C. D. Maciel , J. C. Pereira, “Wavelet time-frequency analysis and least squares support vector machines for the identification of voice disorders,” *Computers in Biology and Medicine archive*, vol. 37, No. 4, pp. 571-578, 2007.
- [65] C. Zhao, C. Zheng, M. Zhao, J. Liu , Y. Tu, “Automatic Classification of Driving Mental Fatigue with EEG by Wavelet Packet Energy and KPCA-SVM,” *International Journal of Innovative Computing Information and Control*, vol 7, No.3, 2011.
- [66] S. Peng, Q. Xu, X. Ling, X. Peng, W. Du , L. Chen, “Molecular classification of cancer types from microarray data using the combination of genetic algorithms and support vector machines,” *FEBS Letters* vol. 555. pp. 358-362, 2003.
- [67] D. C. Anderson, W. Li, D. G. Payan , W. S. Noble, “A new algorithm for the evaluation of shotgun peptide sequencing in proteomics: support vector machine classification of peptide MS/MS spectra and SEQUEST scores,” *Journal of Proteome Research*, vol. 2, No. 2, pp. 137-146, 2003.
- [68] M. S. Brown, W. N. Grundy, D. Lin, N. Cristianini, C. Sugnet, T. S. Furey, M. Ares , D. Haussler, “Knowledge-based analysis of microarray gene expression data using support vector machines,” *Proceedings of the National Academy of Sciences of the United States of America*, vol. 97, No. 1, pp. 262-267, 2000.
- [69] S. Hua , Z. Sun, “A Novel Method of Protein Secondary Structure Prediction with High Segment Overlap Measure:Support Vector Machine Approach,” *Journal of molecular biology*, vol. 308, pp. 397-407, 2001.
- [70] C. Chao, C. Lixuan, Z. Xiaoyong , C. Peixiang, “Prediction of Protein Secondary

- Structure Content by Using the Concept of Chou's Pseudo Amino Acid Composition and Support Vector Machine,” *Protein and Peptide Letters*, vol. 16, No. 1, pp. 27-31, 2009.
- [71] J. Suykens, J. Vandewalle , B. De Moor, “Optimal control by least squares support vector machines,” *Neural Networks* vol.14, pp. 23-35, 2001.
- [72] B. P. Olson, J. Si, J. Hu , J. He, “Closed-Loop Cortical Control of Direction Using Support Vector Machines,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 13, No. 1, 2005.
- [73] P. K. Wong, L. M. Tam, K. Li , H. C. Wong, “Automotive engine idle speed control optimization using least squares support vector machine and genetic algorithm,” *International Journal of Intelligent Computing and Cybernetics*, *International Journal of Intelligent Computing and Cybernetics*, vol. 1 No.4, pp.598 - 616, 2008.
- [74] W. Karush, "Minima of Functions of Several Variables with Inequalities as Side Constraints.," Univ. of Chicago, Chicago, Illinois, 1939.
- [75] H. W. Kuhn , A. W. Tucker, “Nonlinear programming,” *Proceedings of 2nd Berkeley Symposium*.Berkeley: University of California Press., 1951.
- [76] S. Boyd , L. Vandenberghe, *Convex Optimization*, Cambridge University Press, 2004.
- [77] R. COURANT, Variational methods for the solution of problems of equilibrium and vibrations, *Bulletin of the American Mathematical Society*, vol. 49, pp. 1.
- [78] R. Fletcher , M. Powell, A rapidly convergent descent method for minimization, *The Computer Journal*, vol.6, No.2, pp. 163-168, 1963.
- [79] J. Platt, “Fast Training of Support Vector Machines using Sequential Minimal Optimization,” in *Advances in Kernel Methods - Support Vector Learning*, MIT Press, 1998.
- [80] M. Cuturi, J.-P. Vert, Ø. Birkenes and T. Matsui, "A Kernel for Time Series Based on Global Alignment," *Proceedings of ICASSP*, vol. 2, pp. 413-416, 2007.
- [81] M. Cuturi, Fast Global Alignment Kernels, *Proceedings of the 28 th International Conference on Machine Learning*, 2011.

- [82] H. Shimodaira, K. Noma, M. Nakai , S. Sagayama, “Dynamic time-alignment kernel in support vector machine,” Advances in NIPS 14, MIT Press, 2001.
- [83] C. Myers, L. Rabiner , A. Rosenberg, Performance tradeoffs in dynamic time warping algorithms for isolated word recognition, IEEE Transactions on Acoustics, Speech and Signal Processing, vol. 28 , No. 6 , pp 623 - 635 , 1980.
- [84] T. M. Rath, Word image matching using dynamic time warping, Proceedings of Computer Vision and Pattern Recognition2003, vol.2 , pp. 521-527, 2003.
- [85] J. Weston , C. Watkins, “Multi-Class Support Vector Machines,” Royal Holloway Technical report CSD-TR-98-04, 1998.
- [86] C.-W. Hsu , C.-J. Lin, “A Comparison of Methods for Multiclass Support Vector Machines,” IEEE Transactions on Neural Networks, vol. 13, No. 2, pp. 415-425, 2002.
- [87] Y. Lee, Y. Lin , G. Wahba, “Multicategory support vector machines,” Technical Report 1040 Department of statistics, University of Madison, 2001.
- [88] スタッドレスタイヤ使用の手引き, (社) 日本自動車タイヤ協会, 1997.
- [89] 江守一郎, 自動車事故工学, 技術書院, 1993.
- [90] Jebara.T, “MachineLearning: Discriminative and Generative,” Kluwer, 2004.
- [91] J. Lassere, C. M. Bishop , T. Minka, “Principles hybrids of generative and discriminative models,” Proceedings of IEEE Conference on ComputerVision and Pattern Recognition, 2006.
- [92] A. Y. Ng , M. I. Jordan, “On discriminative vs. generative classifiers: A comparison of logistic regression and naive Bayes,” In Advances in Neural Information Processing Systems, 2002.
- [93] 藤野昭典, 上田修攻 , 斉藤和巳, “生成・識別ハイブリッドモデルに基づく半教師あり学習,” FIT2005 第 4 回情報科学技術フォーラム講演論文集, 2005.