

修士論文

車載カメラ画像解析による
運転時の動的走りやすさ推定



東京大学大学院
情報理工学系研究科
電子情報学専攻

学籍番号 48-126451

寺井 真

指導教員 佐藤 洋一 教授

2014 年 2 月

目次

第 1 章	序論	2
1.1	背景	2
1.2	研究の目的とアプローチ	3
1.3	本論文の構成	4
第 2 章	関連研究	5
2.1	車載カメラの画像情報を用いた歩行者視認性推定	5
第 3 章	道路の走りやすさの定義	9
3.1	道路構造に基づく静的走りやすさと走りやすさマップ	9
3.2	交通物体による動的走りやすさ影響量	9
第 4 章	動的走りやすさ推定手法	15
4.1	推定手法の概要	15
4.2	交通物体の検出	15
4.3	各交通物体の状態記述	18
4.4	エリア分割による特徴量設計	20
4.4.1	水平エリア分割	22
4.4.2	放射状エリア分割	23
4.5	統計的学習手法	24
第 5 章	動的走りやすさ推定実験	26
5.1	実験概要	26
5.2	実験データ	28
5.2.1	物体検出データとその精度改善	30
5.3	推定実験結果	32
5.3.1	物体検出精度毎の推定精度	33
5.3.2	交通物体の状態区分毎の推定精度	34
5.3.3	特徴量抽出手法毎の推定精度	36
5.3.4	モデル学習手法毎の推定精度	37
5.4	考察	37

第6章	まとめ	40
6.1	結論	40
6.2	課題と展望	40
	謝辞	42
	参考文献	43
	発表文献	46

目次

2.1	視認性評価値設定の概略	6
2.2	画像特徴による歩行者視認性の推定結果	7
2.3	視認性を考慮した注視点	8
2.4	視認性を考慮した注視点を用いた視認性推定	8
3.1	道路構造に基づく静的走りやすさランク設定	10
3.2	走りやすさマップの例	11
3.3	交通物体の有無による動的走りやすさの変化	12
3.4	動的走りやすさ影響量設定の例	14
4.1	推定手法の流れ	16
4.2	自転車のDPMの例	18
4.3	交通物体の状態による走りやすさへの影響の差	19
4.4	奥行による動的走りやすさ影響量の違い	22
4.5	車線はみ出しによる動的走りやすさ影響量の違い	22
4.6	水平エリア分割(左)及び放射状エリア分割(右)の例	23
4.7	水平分割での隣接領域に対する投票値の重み付けの例	23
4.8	放射状エリア分割での消失点エリアに用いる重みの例	24
5.1	推定実験の流れ	27
5.2	交通物体検出の例	29
5.3	各誤検出識別モデル適用による検出結果一致率	31
5.4	誤検出削減の例	32
5.5	検出精度を可変とした時の動的走りやすさ影響クラス推定一致率	34
5.6	交通物体の状態区分を可変とした時の動的走りやすさ影響クラス推定一致率	35
5.7	分割幅を可変とした水平エリア分割時の走りやすさ影響クラス推定精度	36
5.8	分割幅を可変とした放射状エリア分割時の走りやすさ影響クラス推定精度	37
5.9	統計的学習手法を可変とした時の走りやすさ影響クラス推定精度	38
5.10	動的走りやすさ影響クラス毎の交通物体の出現数平均	39

表目次

2.1	視認性推定に用いた画像特徴量	6
2.2	視認性推定に有効な画像特徴量	7
3.1	道路構造以外の走りやすさの影響要因	11
3.2	識別推定に用いるクラス分類への走りやすさ点数の対応	13
4.1	理想的な物体検出データへの状態ラベル	19
4.2	状態ラベルを用いた交通物体データの区分	21
5.1	動的走りやすさ影響量の分布	29
5.2	物体検出の精度	30
5.3	物体検出データの誤検出削減誤の精度	32
5.4	エリア分割手法での各走りやすさ影響クラスへの混合行列	39

第1章

序論

1.1 背景

我が国において自動車は、長距離近距離問わずの移動のみならず全国的な流通を支えている非常に重要な交通手段である。20世紀半ばより自動車を中心とした道路整備が急速に進められた現在、特に郊外では自動車が無くては生活に支障が出るほどの車社会となっている。近年、世界的な自動車の需要は増大する一方で、それに併せて情報技術を用いて自動車社会の安全性と快適性を向上させる高度道路交通システム ITS(Intelligent Transport Systems) [1] に対する需要も高まっている。昨今では、前方車との距離を検知し自動で衝突を防止するプリクラッシュセーフティシステム [2-4] や、道路側のビーコンから周辺車などの位置情報を取得しドライバーに提示する DSSS(Driving Safety Support System) [5] などが実用化され、今後は自動運転技術の開発などが進むにつれて増々 ITS の研究開発は進むとされている [6]。その他、車載ナビシステムによる適切な運転案内なども依然開発研究が盛んに行われている [7]。

同様に道路ネットワークの ITS に対して、多様化する社会における道路ネットワークのあり方を論ずるために、ユーザー(ドライバー)の選り好みに応じた、ユーザーの視点での道路ネットワークの指標化の検討と評価の重要性が高まっている。これを実現する一種として日本では、デジタル地図を活用した取り組みの一環として、国土交通省道路局により全国の道路の走りやすさを表現した「走りやすさマップ」の構築プロジェクトが実施されている [8]。各道路について道路の構造を基準として走りやすさのランク化を行い、渋滞情報、事故危険箇所、通行規制区間など、「走りやすさ」と関連する情報を記載することで走りやすさマップを構築している。これらにより表現された走りやすさを、Web 上での路線検索システムやカーナビゲーションシステムへの組み込みといった道路利用者への提供と共に、交通安全の観点から道路網の改善を効率的に行う評価手法として活用している。しかしながら、このプロジェクトでは「走りやすさ」の指標基準として車道の車線数や歩道の整備状況といった、静的な道路の構造環境を主に用いて判断している。また、道路の細かな渋滞情報や事故危険箇所の記載も簡便なものである。実際の運転シーンにおいては道路構造的な走りやすさに加えて、道路上に位置する歩行者、車、バイク、自転車といった交通物体の数、配置場所、動きなどの細かな時間と場所により大きく変動する動的な情報が、実際に道路上を交通するドライバーにとっての「走りやすさ」に非常に大きく影響する。これらの要因は、細かな時空間の差異により大きく変化する「動的な要因」であると

言える。しかし、道路ネットワークのITS構築の際にこれら動的要因による走りやすさへの影響は考慮されておらず、道路ネットワーク構築に対して更なる安全性や快適性をもたらすドライバーの感覚的走りやすさが反映されていない問題がある。

1.2 研究の目的とアプローチ

本研究では、動的要因による走りやすさを考慮した道路ネットワーク情報をドライバーに提供することを見据え、そのために必要となる、ドライバーが動的要因に対して実際に感じる走りやすさへの影響を定量的に評価推定することを目的とする。未知の運転シーンにおいて動的要因による走りやすさ影響を定量的に推定することができた時、例えばある時間には子連れの歩行者などドライバーの感じる走りやすさに対して影響の強い交通物体が多くなり、ある道では車道を通行する自転車が多い、といった情報を推定結果傾向より把握することが可能となる。この情報を前述した道路構造についての走りやすさ評価に付随して考えることで、よりドライバー目線に基づいた安全で快適な道路ネットワークを構築できる。また、車車間通信 [9] や交通車による参加型センシング [10] に対して動的要因による走りやすさ影響量の推定を活用することで、同時刻に他の道を走っている車の動的走りやすさ影響量の推定結果を取得することができ、リアルタイムでの道順案内に応用するなどのことも期待できる。本研究ではこれらの動的走りやすさ影響量の応用を踏まえ、運転動作という特性を利用することで動的要因による走りやすさへの影響量を推定する。

そこで我々はまず、ドライバーが感じる運転シーンの走りやすさに影響を与える交通情報を整理する。その中でも特に道路構造に基づいて決定されず、最もドライバーに対して走りやすさに影響を与える交通物体に着目する。交通物体による走りやすさへの影響は、細かな時間や空間に応じて動的に変化するため、本研究では動的走りやすさ影響量と定義する。この動的走りやすさは交通物体の種類、数、状態、位置といった情報に応じて受ける影響の大きさが異なる。また、動的走りやすさ影響量は細かな時間や空間の違いによって大きく変動する量であるため、短時間における交通物体情報によって推定が可能と考えられる。そこで、我々は車載カメラ画像を用い、これら交通物体の情報を運転シーンから抽出し、抽出した情報に応じて運転シーンごとの動的走りやすさ影響量を推定することを提案する。具体的には、まず車載カメラ画像の運転シーンについて動的走りやすさ影響量を正解値として設定する。次に、車載カメラ画像を用いて運転シーンを画像解析し各交通物体を検出する。検出された交通物体情報から、各交通物体の位置に応じた特徴量を抽出する。この特徴量及び設定した動的走りやすさ影響量を用いて、両者の相関関係を統計的に学習することで、車載カメラ画像の特徴量から運転シーンの動的走りやすさ影響量を推定するモデルを作成する。評価実験では、未知の車載カメラ画像に対し、作成した動的走りやすさ影響量推定モデルを適用する。推定モデルにより得られた推定値と、その運転シーンの動的走りやすさ影響量の正解値との一致率によって作成した推定モデルの精度を評価する。これにより、画像解析での交通物体検出とそれを用いた統計的学習手法が動的走りやすさ影響量の推定に有用であることを示す。同時に、この動的走りやすさ影響量推定手法に対して、交通物体の検出精度、交通物体の分類、検出した物体情報の特徴量抽出手法、

及び統計的学習手法といったそれぞれの実験条件を可変とした評価実験を行う。これにより、どのような実験条件において動的走りやすさ影響量を精度よく推定できるかを分析し考察する。運転シーンでの動的走りやすさ影響量の定義、及びその推定を試みた本研究は、我々の知る限り初めての研究である。

1.3 本論文の構成

本稿の構成は以下のようになっている。2章で本研究の関連研究として、画像情報を用いて運転シーンの特性を推定した研究について紹介し、3章では本研究で扱う走りやすさ及び動的走りやすさ影響について説明する。4章では画像から得られた物体情報を元にした動的走りやすさ影響量の推定手法を提案する。5章では提案手法による動的走りやすさ影響量推定の精度を、多様な実験条件の下で評価実験を行い、その結果について議論する。最後に6章で本稿の全体をまとめ、本研究の課題を記す。

第2章

関連研究

本研究は、車載カメラを用いて運転シーンを画像解析し、ドライバーの感覚量である交通物体による走りやすさ影響量の推定を目的とする。車載カメラを用いた運転支援技術としては、歩行者検出 [11, 12], 標識の検出 [13, 14], 前方車との距離の測定 [3, 4], 車線検出 [15, 16] など、多様な先進安全自動車の研究が行われている。しかし本研究は、車載カメラを用いて運転シーンを画像解析するが、推定する対象が交通物体による走りやすさ影響量というドライバーの感覚量を推定するものであり、ドライバーの感覚に基づく運転シーンの特性推定を目的としている。特に運転シーンに対する動的走りやすさ推定の研究はこれまでに行われていないため先行研究などは挙げられないが、本章では関連する研究として車載カメラ画像解析を用いたドライバーの外部情報に対する感覚量の推定を行っている研究を紹介する。

2.1 車載カメラの画像情報を用いた歩行者視認性推定

Engel [17] らは、SVR(Support Vector Regression) [18] を用いて複数の画像情報から歩行者の視認性推定を行った。視認性とは、注目物体がある画像を人が見た時、対象物体やその意味合いを正しく確認または理解できるかどうか、といった感覚を数値化したものである。視認性は対象物体の色合いのみで決まらず、その物体らしさや、周辺背景との色の差、輝度差、形の差、シーン全体の視覚的顕著性や他の物体の視認性など、多くの要因によって影響を受ける [19–24]。

視認性評価値の設定

ここで視認性の評価値の設定が重要となってくるが、短時間の刺激提示に対して視認できたか否か、その統計によって視認性を設定した。その概略図を図 2.1 に示す。これは、まず被験者の視線を画面中央に固定させ、その後刺激画像を 100ms という短時間だけ表示し被験者に対象物体を探させる。その後ノイズ画像を挟んで黒い画面を提示し、被験者は先ほど視認した対象物体の位置を入力する。この位置が実際の対象物体から一定距離以内の正解範囲ならば視認したとみなす。この調査を複数の被験者について行い、正解率をもって各物体の視認性と設定した。




図 2.1: 短時間刺激による視認性評価値設定の概略 [17]

表 2.1: 視認性推定に用いた画像特徴量 [17]

Name	Description
<i>pHoG</i>	Pyramidal Histogram of Oriented Gradients Descriptor as described in [7]
<i>Pos</i>	Position, Size, Color and Standard deviation of the pedestrian
<i>Area</i>	
<i>PedMean</i>	
<i>PedStd</i>	Total number of pedestrians in the image
<i>PedCount</i>	
<i>DiffMean</i>	Difference in mean color, standard deviation and the earth mover distances between difference types of histograms between the bounding box of the pedestrian and its context (see Figure 5))
<i>DiffStd</i>	
<i>DiffHist</i>	
<i>DiffRGBHist</i>	
<i>DiffLABHist</i>	
<i>Dist2Center</i>	Distance from the center of the pedestrian to the center of the image, to the center of the closest other pedestrian and car in the image
<i>Dist2Ped</i>	
<i>Dist2Car</i>	
<i>PixelPerClass</i>	Number of pixels in the image of each of the eight annotated classes the three foreground classes
<i>PixelPerFG</i>	
<i>FixColor</i>	Mean brightness of a 15×15 area around the fixation point in the image and the difference between the fixation point and the mean color of the pedestrian
<i>DiffFix</i>	
<i>mfThres</i>	After resizing the image in the bounding box around the pedestrian to 100×50 , we computed the flux flow \mathcal{F} as described in [15]. <i>mfThres</i> is the number of pixels whose flux flow is above a threshold of 1 and represents the level of symmetry in this area. <i>mfCount</i> is the number of Interest points on the pedestrian. <i>mfMaxScale</i> and <i>mfMeanScale</i> are the largest and average local scales at the interest points.
<i>mfCount</i>	
<i>mfMaxScale</i>	
<i>mfMeanScale</i>	

視認性評価値の推定実験

このようにして設定された各視認性評価値に対して、各シーン画像の画像情報を特徴量として、SVRを用いた統計的学習手法によって相関関係を計算した。各シーン画像について考える画像特徴量を表 2.1 に記載する。ここで、考慮された特徴量それぞれについて視認性評価値との相関関係を SVR にて計算している。その際に歩行者視認性の推定に強く影響する、と SVR によって抽出された特徴量を表 2.1 に示す。これを見ると、対象歩行者のサイズや形状の対称性、注視点からの距離や色度差、周辺背景との輝度差、シーン全体の歩行者数などが、歩行者の視認性に対して影響の強い特徴量として抽出されていることが分かる。

評価実験の結果は図 2.2 のようになり、視認性の真値と推定値に関係性を読み取ることができる。この時、視認性と画像特徴の相関係数は 0.62 であり、データのノイズを考えると高い相関が得られていると言及されている。

表 2.2: 視認性推定に有効な画像特徴量 [17]

Name	Dimensionality
<i>Area</i>	1
<i>PedCount</i>	1
<i>DiffSid</i>	1
<i>DiffHist</i>	51
<i>Dist2Center</i>	1
<i>Dist2Ped</i>	1
<i>DiffFix</i>	1
<i>PedMean</i>	1
<i>PixelPerClass</i>	8
<i>mjCount</i>	1
<i>mjMeanScale</i>	1

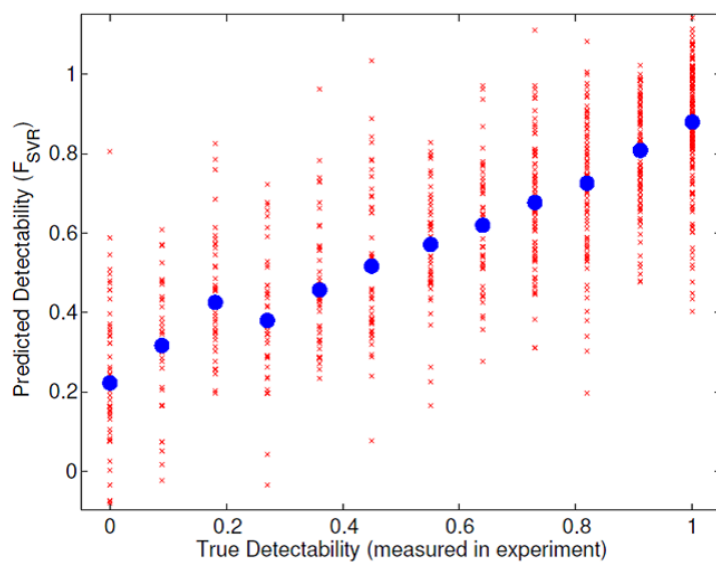


図 2.2: 画像特徴による歩行者視認性推定の実験結果 [17]



図 2.3: 視認性を考慮した注視点の例 [17]




図 2.4: 視認性を考慮した注視点を用いた視認性推定 [17]

視認性を用いた安全運転支援

対象物体の視認性は、現在の注視点からの距離や色度差により影響される。そのため、複数の歩行者がいる運転シーンでは、現在の注視点の位置により各歩行者の視認性はそれぞれ異なる。これを用いて、複数の歩行者がいる運転シーンで歩行者全体の視認性を最大化するような注視点位置の推定手法が提案されている。つまり、図 2.3 では、赤点が画像内歩行者の単純な位置の重心を示しており、青点が推定した歩行者視認性の低さを重みとして用いた際の重心となっているが、青点を注視点としたとき画像内の全歩行者に対する視認性平均は上昇すると考えている。

そこで歩行者視認性を考慮した位置に注視点を設定し、歩行者の視認性評価値を先ほどと同様に短時間刺激画像をもって測定した。実験の結果は図 2.4 のようになり、視認したとする正解範囲をどのような大きさとしても、注視点を歩行者視認性を考慮した位置に設定することで全歩行者の視認性平均が上昇していることが分かる。

これを用いることで、より安全性の高い注視点位置をドライバーに対して提示するシステムが考えられる。更に歩行者だけでなく他の交通物体について適用することで、運転シーン全体の視認性平均の向上が期待される。

第3章

道路の走りやすさの定義

本研究は、運転作業時のドライバーの走りやすさという感覚が交通物体から受ける影響量を機械的に推定することを目的とするため、走りやすさを定量的に表現する必要がある。本章ではそのために、まず道路の走りやすさマップ [8] で用いられている道路構造に基づいた静的な走りやすさを説明し、その後本研究で扱う交通物体によってドライバーが影響を受ける動的走りやすさ影響量の定義について述べる。

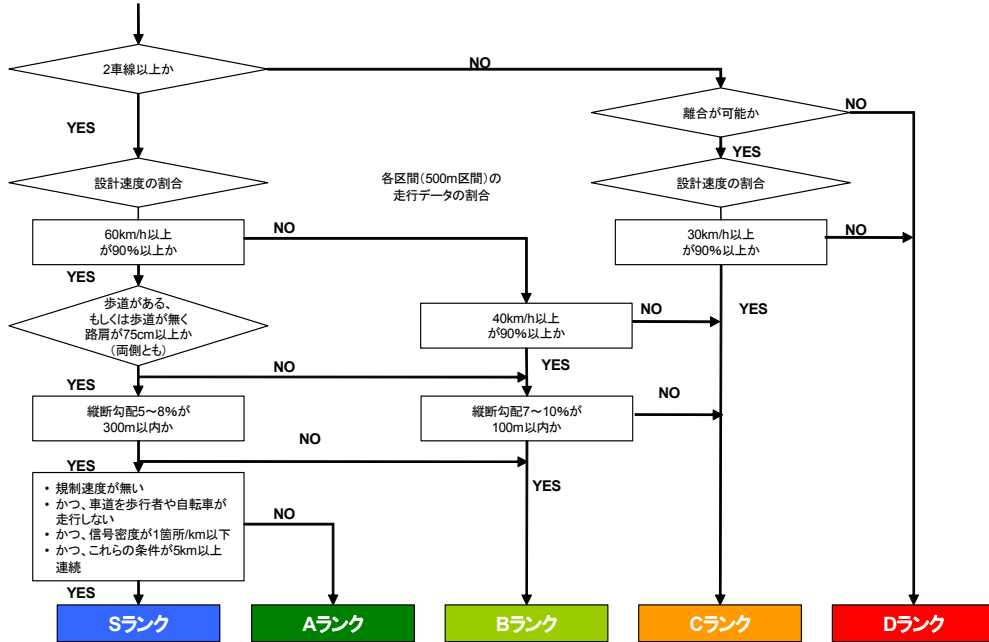
3.1 道路構造に基づく静的走りやすさと走りやすさマップ

日本国土交通省は、道路構造に応じた道路の静的走りやすさランクを定義し、ユーザー視点に立った道路ネットワーク ITS の構築プロジェクトとして走りやすさマップ構築を実施している [8]。ここでは、ドライバーが走行する際の「走りやすさ」には、道路構造的な要因、走行速度 (渋滞) に関する要因、方向安全性 (事故) に関する要因の3つが考えられ、各要因を複合して記載することで走りやすさマップを構築している。道路構造的な走りやすさ要因は図 3.1 のように定められ、対象とする道路の車線数、カーブの曲率、及び歩道の有無という道路の構造によって4,5段階のランクで表される。これは道路構造という時間や道路内の局所的な場所に対して不変的な量であり、静的な走りやすさといえることができる。郊外部及び山地部での評価方法と市街地部での評価方法が異なるが、これは市街地部における歩行者の交通量を考慮し、歩道の存在を重要視した評価方法となっているためである。走行速度および走行安全性に関する走りやすさ要因は、それぞれ渋滞ポイント及び事故危険個所をマップ上に記載することで走りやすさマップに用いている。この静的走りやすさランクに基づいてマップ上の各道路を色により区分し、図 3.2 に例を示す走りやすさマップを構築している。このようにして構築された走りやすさマップは、Web 上での路線検索システムやカーナビゲーションなどへの組み込みや、交通安全性の観点での道路網の状況の評価などに用いられ、安全で快適な道路ネットワークの実現に対し有効に機能している。

3.2 交通物体による動的走りやすさ影響量

走りやすさマップで用いられている走りやすさは、車道の車線数や歩道の整備状況といった、静的な道路の構造環境のみを用いて判断している。しかし、実際の運転シーンにおい

郊外部・山地部の評価フロー



市街地部の評価フロー

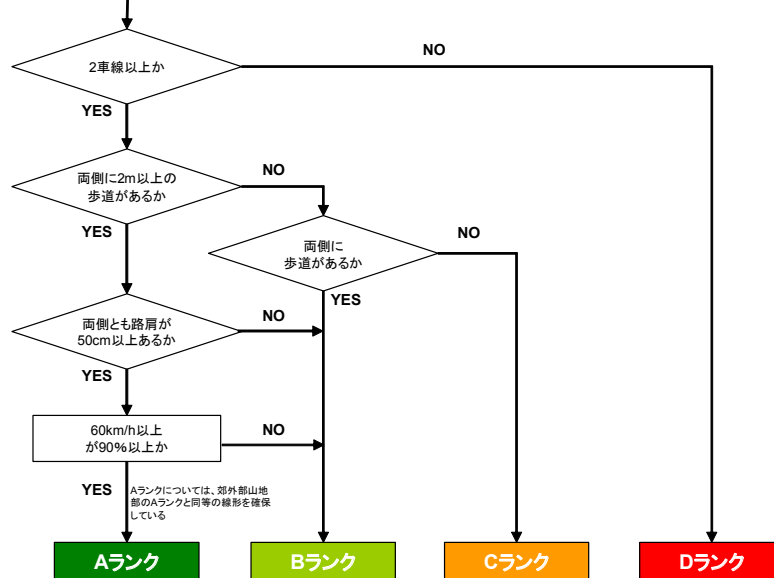


図 3.1: 道路構造に基づく静的走りやすさランク設定 [8]



図 3.2: 走りやすさマップの例 [8]

表 3.1: 道路構造以外の走りやすさの影響要因

種類	走りやすさに影響する事象
道路環境	電柱, 路上駐車, 駐輪, 工事, 事故, 見通し
交通状況	歩行者, 対向車, 周辺車, 大型車, バイク, 自転車
天候	天候不良, 光量変化

てドライバーが感じる走りやすさは、道路構造的な走りやすさに加えて走行車の周辺に存在する交通物体や交通状況により強く影響を受ける。図 3.3 を見比べると、同じ道路環境においても交通物体の有無により運転時に感じる走りやすさに差があると考えられる。走りやすさマップに用いられている交通要因として、静的走りやすさの他に渋滞情報及び事故危険箇所を記載しているが、これらも細かなドライバーの感じる走りやすさを記載したものではなくドライバーの感覚に沿ったものではない。そこで本研究では、運転シーンから確認できる交通物体や交通状況から走りやすさへの影響を定義し、よりドライバーの感覚に対応した走りやすさの表現を行う。以下で、本研究で交通物体による動的走りやすさ影響量をどのように定義し、定量的に扱うかを説明する。

運転シーンに影響を与える道路構造以外の要因は様々考えられるが、大別すると道路環境、交通状況、天候の3種について考えられる。これら3種の分類を元に、走りやすさに影響を与えると考えられる交通上の各事象として、表 3.1 のように14種を列挙できる。細分化などにより種類数は前後するが、本論文ではこれら14種の交通事象がドライバーが感じる走りやすさへ影響を及ぼすものとする。



図 3.3: 交通物体の有無による動的走りやすさの変化

今、本研究の目的であるドライバーが感じる走りやすさへの影響を推定するという視点から、道路構造以外の走りやすさへの影響要因 14 種について考える。まず、事故、工事、天候不良、光量変化といった情報は他の影響要因と比較して、ニュースなどにより情報の取得が容易だと言える。また、電柱や見通しについては基本的に場所毎に一定な静的要因である。これらを除いて考えると、道路構造以外の走りやすさは、車、歩行者、自転車、バイクといった交通物体によって影響を受ける。そのため、ドライバーの感覚に応じた走りやすさの推定には、交通物体について情報を取得する必要がある。交通物体の情報は時間や場所によって一位に定められない。そのため、車、歩行者、バイク、自転車といった交通物体を、ドライバーの感じる走りやすさに動的な影響を与える要因だと言える。本研究ではこれら交通物体から受ける走りやすさへの影響を動的走りやすさ影響量として定義し、定量的な推定を試みる。なお、交通物体以外の要因による走りやすさへの影響は既知のものとして扱うが、道路環境についての走りやすさへの影響のうち、路上駐車及び駐輪については交通物体に依存した動的に変化しやすい影響項目であるため、交通状況と共に推定対象とする。動的要因として、表 3.1 の該当項目に下線を引く。

ここで、今目標としているのはドライバーの感覚に沿った走りやすさの推定である。ドライバーは、運転シーンの情報取得のために、主にドライバー自身の視覚情報を元に各交通物体を視認し、走りやすさを感覚量として知覚する。また、動的要因による走りやすさは細かな時間や空間の違いによって大きく変動するため、短時間における交通物体情報によって推定が可能と考えられる。そのため、本研究ではこのドライバーの走りやすさ知覚の知見に基づいて、車載カメラによる画像情報を元に各走りやすさへの影響の推定を考える。つまり、本研究は動的走りやすさの影響を画像解析による交通物体検出情報を用いて定量的に推定することを目指すものである。そのため、各運転シーンに対して動的走りやすさ影響量を定量的に定義する必要がある。以下では、動的走りやすさ影響量を具体的にどのように設定したのかを説明する。動的走りやすさ影響量は、車載カメラ画像の運転シーンそれぞれについて設定する。各運転シーンを複数のドライバーに見せ、表 3.1 の下線を引いた項目それぞれについて実際の運転作業で走りやすさに影響を与えるかどうか、危険／やや危険／安全、の 3 段階の危険度合でそれぞれ主観評価させる。この時、全ドライバーの回答で最も多かったものを運転シーンの各項目について危険度合として決定する。得られた危険度合に応じて、危険：-10 点／やや危険：-5 点／安全：-0 点といった基準で、それ

表 3.2: 識別推定に用いるクラス分類への走りやすさ点数の対応

走りやすさ影響量	走りやすさ影響クラス
-0点	-0点クラス
-5点	-10点クラス
-10点	
-15点	-20点クラス
-20点	
-25点	-30点クラス
-30点	
-35点	

ぞれの項目に対する動的走りやすさ影響量を点数化する。それぞれの項目に対して設定された点数を画像毎に足し合わせることで、その運転シーンの動的走りやすさ影響量として点数化する。各項目ごとに減点幅を決定するため、それらを統合した動的走りやすさ影響量の幅は広く考えられるが、実際の道路状況についての影響量は-0点~-40点といった減点幅となっている。

ここで、本研究は動的走りやすさ影響量の ITS 実用を踏まえたものである。そのため、4もしくは5クラスで表現されている静的走りやすさランクと統合させた走りやすさ推定のシステムの実用を踏まえた時、同程度に量子化した動的走りやすさ影響量を用いることで、より直観的な対応付けが可能である。本研究では、暫定的ではあるが動的走りやすさ影響量もその点数に応じて4クラス分類を行い、5点刻みであった動的走りやすさの影響量を10点刻みによる-0点、-10点、-20点、-30点の4クラスに落とし込む。表3.2に具体的な影響クラスへの対応を示す。本研究では、ここで定義した4クラスの動的走りやすさ影響クラスについて識別推定を行う。

各画像の動的走りやすさへの影響量点数化の例として図3.4の運転シーンを見てみると、歩道が無く飛び出す危険性もある歩行者を危険(-10点)、1車線なので意識しなければならない対向車をやや危険(-5点)、といった項目がドライバーの主観評価調査によって決定され、合計点である-15点が表3.2に従って動的走りやすさ影響クラスとして-20点クラスとなる。




図 3.4: 動的走りやすさ影響量設定の例

第4章

動的走りやすさ推定手法

従来の道路ネットワークについての運転支援技術では、基本的な道路の構造に則した最適な道順提案がされてきたが、ここには各道路の細かな状況による影響、特に時間や空間により複雑に異なる、交通物体による道路の走りやすさへの影響に対応できないという課題があった。この問題を解決するためには実際の運転シーンにより各道路の交通物体についての動的走りやすさを推定することが必要である。そこで本章では、動的走りやすさ推定手法について述べる。車載カメラにより交通物体の検出を行い、その物体情報から統計的学習モデルにより動的走りやすさへの影響量を推定する手法を説明する。

4.1 推定手法の概要

本論文で提案する動的な走りやすさの推定手法の流れは、図4.1のようになる。運転シーンを映した車載カメラ画像群を入力データとして扱う。入力データからはまず画像特徴を元に交通物体の検出を行う。同時に、各運転シーンについて動的な走りやすさ影響量の点数化を、節3.2で述べた手順に従って行う。検出された交通物体からは、その位置データに応じて走りやすさ推定のモデルに用いる特徴量を抽出する。以上で得られた、運転シーンについての走りやすさ影響量及び交通物体についての特徴量のデータセットから、統計的学習手法を用いて動的走りやすさ影響量を推定するモデルを作成する。

4.2 交通物体の検出

交通物体が及ぼす動的走りやすさへの影響量を推定するために、車載カメラ画像から歩行者、自動車、バイク、自転車の4種の交通物体を検出する。1枚の画像から人物を検出するアプローチとして、人物の特徴をあらかじめモデル化し、その特徴に合致する画像領域を対象画像から抽出する手法が考えられる。対象とする人物の特徴モデルは多様にあるが、本論文では近年画像での物体認識で広く用いられているHOG(Histograms of Oriented Gradients) [25] 特徴量によるDPM(Deformable Part Model) [26] を用いて統計的に学習モデルを作る。本研究では、対象となる交通物体それぞれに対してDPMを作成する。その後、実験データとなる画像内の画像領域に対して各対象物体のDPMとの一致率を求め、各交通物体について手入力により設定した閾値以上の一致率をもって交通物体が検出された、

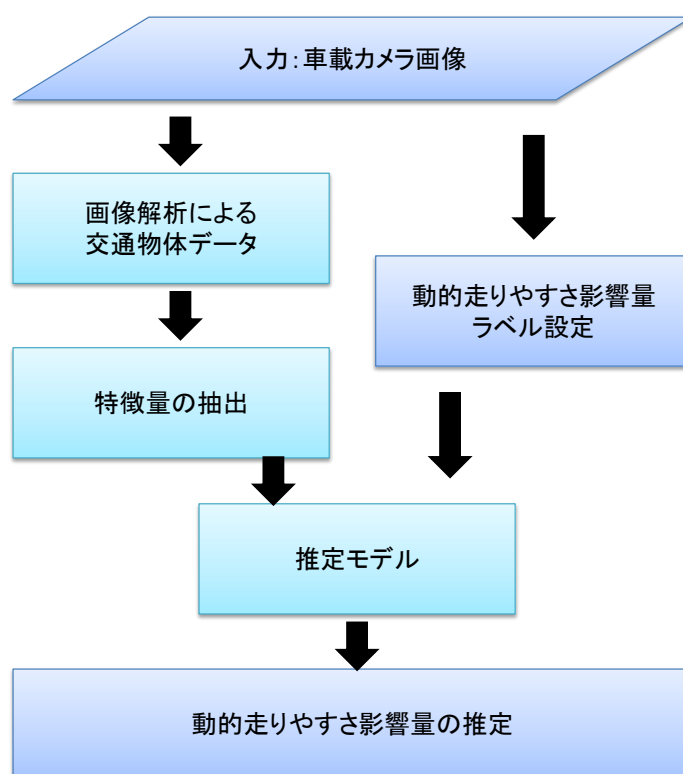


図 4.1: 推定手法の流れ

とする．その画像領域について交通物体の種類，位置，領域のサイズを物体情報として取得し，動的走りやすさ影響量の推定に用いる．以下，画像特徴である HOG 特徴量と特徴量のツリー構造モデルである DPM について説明する．

HOG 特徴量

HOG(Histograms of Oriented Gradients) は N.Dalal らにより 2005 年に提案された画像特徴量であり，検出物体毎に統一スケールされた対象画像を複数のブロック状局所領域に分割し，各局所領域での輝度の勾配方向をヒストグラム化し，連結させた特徴量である．そのため照明変動や局所的な幾何学変化に対して頑健に物体の形状を捉えることができ，形状変化が起こりうる人物検出などに適した特徴量であり，本研究でも物体検出に用いる．HOG 算出のアルゴリズムは以下ようになる．まず入力画像の各ピクセルの輝度 $I(u, v)$ から，勾配強度 $m(u, v)$ と勾配方向 $\theta(u, v)$ を式 4.1 により算出する．

$$f_u(u, v) = I(u + 1, v) - I(u - 1, v), \quad (4.1)$$

$$f_v(u, v) = I(u, v + 1) - I(u, v - 1), \quad (4.2)$$

$$m(u, v) = \sqrt{f_u(u, v)^2 + f_v(u, v)^2}, \quad (4.3)$$

$$\theta(u, v) = \arctan \frac{f_v(u, v)}{f_u(u, v)}. \quad (4.4)$$

次に，入力画像をあらかじめ定めた画素サイズによって格子状に分割し，複数の画素の集まりを得る．これをセルと呼ぶ．ここで各セルに含まれる画素の勾配方向を量子化し，各量子化方向 θ についてのヒストグラム $v_c(\theta)$ を式 4.5 により算出する．本研究では，セルのサイズを 5×5 ピクセル，量子化勾配方向を 8 方向とした．

$$v_c(\theta') = \sum_u \sum_v m(u, v) \delta[\theta', \theta(u, v)]. \quad (4.5)$$

$\delta[\theta', \theta(u, v)]$ は Kronecker のデルタ関数と言い， $0 - 180^\circ$ の勾配方向 θ を量子化した値が量子化勾配方向 θ' と一致した時に 1 を返す関数である．最後に，ブロックの大きさを定め，そこに含まれる複数のセルの量子化勾配方向ヒストグラムを連結し，正規化させる．ブロック領域を，セルの重なりを許しながら 1 セルずつ移動させた時の，ブロックに含まれるセルの量子化勾配方向ヒストグラムを連結し正規化したものを各ブロックの特徴量とする．本研究では 3×3 セルを 1 ブロックとしてヒストグラムを正規化する．

DPM

DPM(Deformable Parts Model) は P.F.Felzenszwalb により 2008 年に提案された画像特徴量モデルの一つであり，図 4.2 のように対象物体を複数パーツによるツリー構造と捉えたときの各パーツの HOG を計算し，各パーツの HOG，画像領域全体の HOG，各パーツの




図 4.2: 自転車の DPM の例 [26]

位置関係の特徴量として用いる特徴量モデルである。詳細は [26, 27] を参照にされたい。本研究では交通物体の種類ごとの DPM を元に、車載カメラ内から各交通物体を検出し、各 DPM との一致率が手動で定めた基準以上の画像領域を交通物体が存在する領域として用いる。

4.3 各交通物体の状態記述

本研究では、交通物体の物体情報が検出されたとき、動的走りやすさ影響量を推定する。そのため本手法の有効性を示す動的走りやすさ影響量の推定精度は、物体検出の精度に左右されてしまう。そこで、物体検出の精度に依存せずに動的走りやすさ影響量の推定精度を議論するために、物体検出による交通物体データの取得と同時に、手入力により交通物体データを作成し、動的走りやすさ影響量の推定実験に用いる。

また、ここで交通物体の検出によって得られる情報は、車、歩行者、バイク、自転車という4種の交通物体の種類、大きさ及び位置の情報である。しかし、例えば図 4.3 で比較するような、柵に囲まれた歩行者と車道に飛び出す可能性の強い歩行者とでは、ドライバーが受ける走りやすさへの影響は異なると考えられる。このように、交通物体の状態や性質などによって動的な走りやすさに与える影響は異なるため、交通物体の状態を画像特徴量として把握し走りやすさ推定に用いることで、動的走りやすさ影響量の推定精度向上が期待できる。そのため本研究では、大型車／普通車や、歩道走行／車道走行といった状態毎に交通物体情報を分類し、動的走りやすさ推定に用いる。交通物体の区分を複数段階で行い、その区分によって動的な走りやすさ推定にどれほど影響が出るかを議論する。ここで、交通物体の状態記述は交通物体の検出を前提としたものなので、状態記述に基づく動的走りやすさ影響量の推定精度は物体検出の精度に左右される。本論文では状態記述のみによる動的走りやすさ影響量の推定精度について議論するために、前述した手入力による理想的な物体情報に対して状態記述を行う。以下、本論文で考える各種交通物体の状態記述について具体的に述べる。




図 4.3: 交通物体の状態による走りやすさへの影響の差

表 4.1: 理想的な物体検出データへの状態ラベル

物体の種類	状態ラベル 1	状態ラベル 2
車	普通車／大型車	走行中／路上駐車中
歩行者	歩道内／車道内	安定歩行／危険歩行
バイク	歩道／車道内	安定走行／危険走行／非乗車
自転車	歩道内／車道内	安定走行／危険走行／非乗車

具体的な状態記述法について

本研究では交通物体の状態毎の区分を行うために、交通物体情報に対してそれぞれ表 4.1 に示す 2 種の状態ラベルを設定する。その後、設定した状態ラベルの組み合わせに応じて交通物体の区分を段階的に行う。具体的には、まず車はその大きさにより普通車と大型車に大別される。車線上に路上駐車されている車も運転作業によって避ける必要があるため区別する。また、人が乗っていないバイクや自転車は走りやすさに影響しないと考えられるが、交通物体検出シーンにおいて検出され動的走りやすさ影響量の推定モデルに悪影響を与えてしまうため、非乗車の交通物体として区別する。他に考えられる状態記述として、これは道路構造によっても変化するものだが、歩道を走っている自転車がある状態よりも車道外側線付近を走っている状態、及び車道内を走っている状態とでは、ドライバーはより後者になるにつれて自転車への注意を払わなければならない。そのため、各交通物体が検出された場所に応じて状態ラベルで区別する。また特に歩行者や自転車は、歩道を交通していたとしても容易に車道に出ることができ、横断しようとしている交通物体や、歩道が急に狭くなる場所などに応じて車道にはみ出てくる可能性が強い。そのため、これはドライバーの個人差により影響にも差が出てくることなのだが、交通物体の危険性について区別も行う。本研究では、歩行者及び走行中の自転車が、歩道幅の半分よりも近く車道側に位置し、かつガードレールや柵などが交通物体の脇または前方付近に存在しない状態を、危険な交通物体と定義する。以上で述べた交通物体の状態を、表 4.1 に示す 2 種の状態ラベルの組み合わせによって区別する。

状態毎の区分による走りやすさ影響量推定

この状態ラベルを用い、交通物体を状態毎に区別して走りやすさ影響量の推定実験を行う。ここで、今回設定した状態ラベルは人の目で判断した状態である。走りやすさ影響量の実用を考えると画像特徴などより解析推定し、自動的に状態ラベルを振り分ける必要があるが、今回設定した状態ラベルを位置と大きさのみからなる物体検出データから推定することは難しい。

しかし、車線検出が行え、歩道の有無などが識別でき、ガードレールの検出も可能となり、また物体検出の位置精度が十分に保障でき、前後フレームとの対応により交通物体の動きを検出できた、と仮定すると、車線との相対位置情報や交通物体の正確な大きさや向きにより、自動的な状態ラベル振り分けが可能となる。そのため、これら道路情報の取得状況によって可能となる状態ラベル設定は異なる。そこで、本実験では道路情報や交通物体情報の取得状況に応じて、状態ラベル割り振りによる交通物体の状態記述を複数行う。具体的な区分を表4.2に示す。これは、区分Aは交通物体の検出精度の向上により、自転車及びバイクの上方に人が検出されたか否かで人が乗車していない自転車やバイクなどドライバーの走りやすさに影響を与えないものを除外できたと仮定した区分である。また区分BはAに加え、交通物体の足元座標の正確な検出及び車線検出により、交通物体の位置が車道か否か、及び自動車の大きさと足元座標により大型車か否かを識別できたと仮定した区分である。さらに区分CはBに加え、ガードレールや歩道の柵の検出、歩道内の位置情報、及び前後フレームとの相関による動き検出、などにより交通物体が車道にはみ出す危険性や、駐車車両などを識別推定できたと仮定した区分である。このような実験データの交通物体を状態によって区分することが動的走りやすさ影響量の推定に対してどう影響するかを議論する。

4.4 エリア分割による特徴量設計

車載カメラ画像について得られた交通物体の位置情報を用いて動的走りやすさの影響量を推定するために、交通物体の情報から特徴量を適切に設定する必要がある。最も単純に考えられる特徴量の設定法として、車載カメラ画像に各種の交通物体がどの程度出現したかという出現個数情報を特徴成分とするものである。しかしながら、実際の運転シーンにおいてどのような交通物体がドライバーにとっての動的走りやすさに影響を与えるかを考えると、前述の単純な出現個数情報のみでは不足する。

例えば、図4.4のような運転シーン画像において、歩行者Aと歩行者Bではドライバーが感じる動的走りやすさへの影響は異なってくる。これは、この画像について考えると、歩行者Aは歩行者Bと比べて自車の近くに位置するために、ドライバーは歩行者Aを意識して回避する動作をとるための時間が短く、Bよりも動的走りやすさへの影響が大きい、と考えられる。また図4.5のように、車道に飛び出ている歩行者Cと歩道を歩いている歩行者Dを比べると、歩行者Cはより動的走りやすさへの影響が大きく感じられるが、これは車道に出ていることによりドライバーが歩行者を回避する距離が長くなり多くの作業時間が必要となるためである。以上の運転作業についての知見から、自車との距離感と車道

表 4.2: 状態ラベルを用いた交通物体データの区分

交通物体	区分無し	区分A	区分B	区分C
自動車	自動車	自動車	普通車	普通車
			大型車	大型車
歩行者	歩行者	歩道者	歩道歩行	歩道安全歩行
			車道歩行	歩道危険歩行
バイク	バイク	非乗車除いたバイク	非乗車除いたバイク	非乗車除いたバイク
自転車	自転車	非乗車除いた自転車	歩道走行	歩道安全走行
			車道方向	歩道安全走行
総区分数	4種	4種	7種	10種




図 4.4: 奥行による動的走りやすさ影響量の違い




図 4.5: 車線はみ出しによる動的走りやすさ影響量の違い

との距離感、の2種が動的走りやすさへ影響が大きいと考えられる。これらを考慮し、本研究では出現物体の位置に応じて出現個数情報を特徴成分とする手法を提案する。以下で、出現個数情報の数え上げに用いる領域分割の手法として、水平エリア分割手法と放射エリア分割手法の2種の特徴量設定法について述べる。

4.4.1 水平エリア分割

交通物体と自車との距離感を表す特徴量設定法として、図 4.6 左に示すような水平方向のエリア分割が考えられる。これは任意の分割数となるよう、車載カメラ画像を分割数で水平に均等分割し、各種の交通物体の足元座標がどの分割エリアに位置するのかを各エリアごとに計上したものである。車載カメラは前方を向いているため、自車に近い交通物体は画像の下端側に位置するので、この水平エリア分割によって自車との距離感を表現し、特徴成分として用いる。この時エリア領域の境界近くに交通物体が存在すると、検出のブレによって量子化誤差が生じやすい問題がある。これを軽減するために、交通物体の足元座標が存在するエリアと、次に足元座標から近いエリアとに対し、その位置に応じた線形な重み付けにより両方に投票を行う。図 4.7 に示すように、足元座標が存在するエリア 1 の中心線までの距離を d_1 、次に近い隣接するエリア 2 の中心線までの距離を d_2 とした時、エリア 1 への投票値 w_{h1} 及びエリア 2 への投票値 w_{h2} は、下式のようなになる。

$$w_{h1} = \frac{d_2}{d_1 + d_2}, \quad (4.6)$$




図 4.6: 水平エリア分割 (左) 及び放射状エリア分割 (右) の例

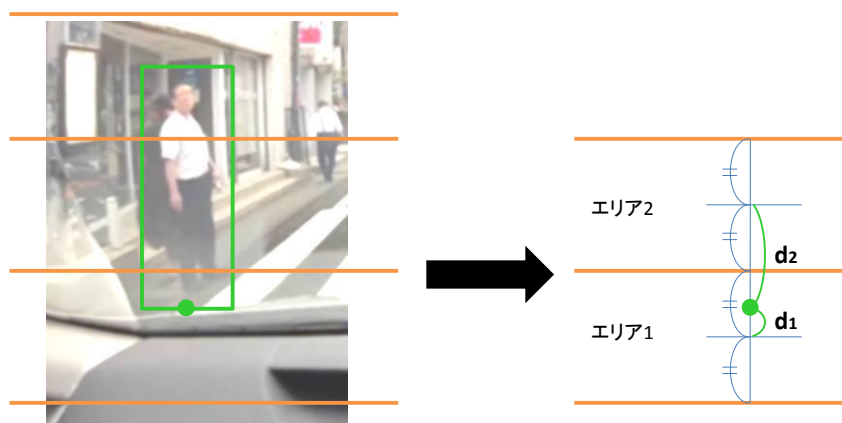


図 4.7: 水平分割での隣接領域に対する投票値の重み付けの例

$$w_{h2} = \frac{d_1}{d_1 + d_2}. \tag{4.7}$$

4.4.2 放射状エリア分割

交通物体と自車線との距離感を表す特徴量設定法として、図 4.6 右に示すような放射方向のエリア分割が考えられる。これも水平エリア分割と同様に考えて、車載カメラ画像を自車が向かう先(消失点)を中心とした放射状に分割する。ここで、分割数は任意の整数として各角度を均等に分割する。これにより交通物体の、奥行を考慮した道路上の水平位置を量子的に表現できる。ここでも水平エリア分割時と同様に、量子化誤差を軽減するために隣接エリアの中心軸への距離に応じた線形な投票を行う。同時に、消失点付近ではこの線形投票を超えた検出ブレにより量子化誤差が危惧されるため、消失点付近を別エリアとして考える。そのため、放射状エリア分割での投票はエリア 1, エリア 2, 消失点エリア、の 3 つに対して行われる。つまり、消失点との距離に応じた重みを両放射エリア及び消失点エリアについて設定し、その後放射エリア 1 及びエリア 2 について各中心軸への距離に応じて重みを設定する。

前述した放射エリアと消失点エリアとの重みについて、各放射エリアへの投票は消失点

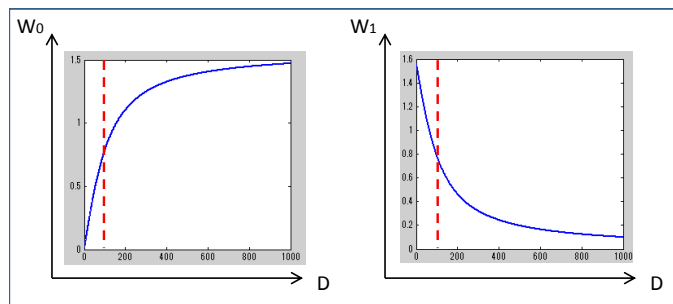


図 4.8: 放射状エリア分割での消失点エリアに用いる重みの例

からの距離の小さい部分では重みを小さくし，一定以上の距離を持つ部分には同様の重みを設定する．このような飽和特性を持たせるため，

$$w_{in} = \text{atan}(\alpha l). \quad (4.8)$$

に示す逆正接関数を用いて消失点からの距離 l に応じた重み付け投票をする．本研究では 1920×1080 pixel の画像に対し $\alpha = 0.01$ と設定した．消失点付近の検出は放射状エリアとは別の領域として設定する．消失点エリアへの投票は，消失点からの距離に応じてソフトに行うため，エリア境界はないが，図 4.6 右等の放射状エリアを表す図では，便宜上境界線を表示している．消失点への重みは， w_0 の最大値である $\pi/2$ から，放射エリアへ計上分を引き，

$$w_{out} = \pi/2 - w_{in}. \quad (4.9)$$

として定義する．この重みの例を図 4.8 に示す．

次に放射エリアと隣接する放射エリアについての重みを，水平エリア分割時と同様に考えて設定する．図??に示すように，足元座標が存在するエリア 1 の中心線までの角度を θ_1 ，次に近い隣接するエリア 2 の中心線までの角度を θ_2 とした時，エリア 1 への投票基準値 w_{r1} 及びエリア 2 への投票基準値 w_{r2} は，下式のようなになる．

$$w_{r1} = \frac{\theta_2}{\theta_1 + \theta_2}, \quad (4.10)$$

$$w_{r2} = \frac{\theta_1}{\theta_1 + \theta_2}. \quad (4.11)$$

これら各エリアに対する 2 種の重みを用いて，エリア 1 への投票値は $w_{out}w_{r1}$ ，エリア 2 への投票値は $w_{out}w_{r2}$ ，消失点エリアへの投票値は w_{in} となる．これを用いて計上を行う．

4.5 統計的学習手法

本論文では，入力データである車載カメラ画像に対して物体検出して得られた交通物体情報から，各特徴量設定法を用いて特徴量を得，これと人手により走りやすさがラベル付

けされた学習データに基づいて、動的走りやすさへの影響量を推定する。本節では、その推定で用いる統計的学習手法について述べる。本研究ではサポートベクターマシン (SVM, Support Vector Machine) [28], 及びk近傍法 (k-Nearest Neighbor algorithm) [29]を用いる。SVMは近年画像認識の分野において多数の研究で用いられるツールであり、本研究の関連研究として挙げた歩行者視認性推定の研究においても統計的学習手法として用いられている。これはSVMがマージン最大化やソフトマージンなどの工夫により見学習のデータに対する汎用性を高め過学習が起きにくくしているなどの理由による。次にk近傍法は対象となるデータの局所的な特徴成分構造を重視する統計的識別手法であるため、SVMとの比較により動的走りやすさ影響量の推定における特徴成分構造の局所性を確認することができる。以上の理由により、本研究での統計的識別手法としてSVM及びk近傍法を用いる。以下で、各統計的識別手法について簡単に述べる。

SVM

SVMは識別能力に優れた手法として昨今知られている統計手法であり、マージン最大化やソフトマージンなど種々の工夫によって未学習のサンプルへの汎化性が高く過学習を起しにくい。特に線形SVMは多次元特徴でも有効に識別可能である。そのためSVMは近年多くの画像認識分野に適用されているツールであり、本研究の関連研究となる歩行者の視認性推定 [17]でもSVMが用いられている。よって本論でも線形SVMを用い、動的走りやすさ影響量推定の基準とする。SVMは、識別推定では識別面と学習サンプルとの最少距離 (マージン) を最大化するように識別面を決定する。SVMによる識別推定について、詳しくは [30] を参照にされたい。

SVM実装に際して本研究ではLIBSVM [31]を用いる。モデル学習時には特徴量を各次元毎に平均0、標準偏差1となるようにスケーリングを行い、学習に用いる。SVMのパラメータに関しては、Cross-validation [32]により各実験での最適なパラメータを発見し適用する。また、4クラスへの識別問題に2クラス識別器であるSVMに対応させるためには、複数の2クラス識別器を組み合わせることで多クラス識別器を構成する必要がある。本研究では、一般に予測精度が高いとされる一対一法によって多クラス識別器を構成する [33]。

k近傍法

k近傍法は、探索距離kを定めた時に特徴量の距離が近い学習データk個について正解ラベルを調べ、その多数決によりラベル推定する統計手法である。そのためk近傍法は各データの局所的構造を重視する統計手法であり、SVMとの比較により動的走りやすさ推定の局所性を確認するため本実験で用いる。ここで、k近傍法は各特徴量次元に対して均等な重み付けで距離を計算するため、次元が多数ある特徴量の構造では識別性能が低下してしまう [29]。これを回避するため本実験でのk近傍法によるクラス判別では、特徴量空間を線形判別分析 [34]によって次元を圧縮することで、クラス判別に有効な次元を強調し、影響の無い次元の影響を抑える。

第5章

動的走りやすさ推定実験

動的走りやすさ推定に対する提案手法の有効性を評価するために、多様な実験条件において動的走りやすさ影響量を推定する実験を行った。

5.1 実験概要

交通物体による動的な走りやすさへの影響量の推定実験を、節4で述べた手法に沿って行う。推定実験の概略図を図5.1に記す。基本的な実験の流れは、まず複数の車載カメラ画像に動的走りやすさ影響量を点数として付けたものを実験データとして用意する。画像特徴を元に、各画像から対象となる交通物体を検出し、その検出データを元にして走りやすさ推定に用いる特徴量を抽出する。得られた特徴量から動的走りやすさ影響量を推定するモデルを統計的学習手法により作成し、テストデータにモデルを適用した時に推定された動的走りやすさ影響量と、正解となるクラスが一致したか否かによってモデルの精度を算出する、というのが本実験の主な流れである。

本実験では、本論文で定義した動的走りやすさへの影響量というドライバーの感覚量を精度よく推定する手法を考察するために、以下にあげる複数の実験条件を可変として実験を行う。

条件1：交通物体の検出精度

条件2：交通物体の状態記述

条件3：エリア分割手法による運転シーン画像の特徴量抽出手法

条件4：統計的学習手法の選択

これら可変条件について以下で説明する。

条件1：交通物体の検出精度について

本論文は画像解析による交通物体の検出データに対して特徴量抽出を行い、得られた特徴量を元に動的走りやすさ影響量を推定する。そのため動的走りやすさ影響量の推定精度は交通物体の検出データ精度に依存し、本手法において物体検出精度は動的走りやすさ影響量の推定精度を左右する重要な要素であると言える。そこで、本実験では物体検出の精

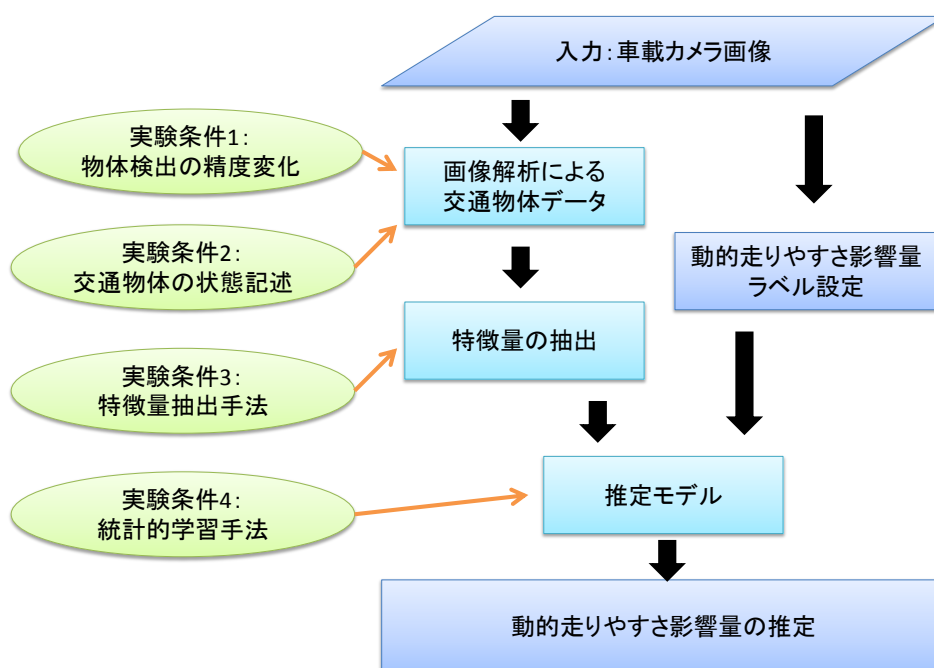


図 5.1: 推定実験の流れ

度を変えた交通物体データを複数用意し、それぞれの物体データにおける動的走りやすさ影響量の推定実験を行い、評価する。具体的には節 5.2.1 で後述するが、節 4.2 で説明した HOG 特徴に基づく DPM を用いた物体検出結果と、これに対して新たな統計的学習モデルにより誤検出を削減した物体データ、手入力により誤検出を削減した物体データ、全ての交通物体に対して手入力で検出した理想的な物体データ、の 4 種類の物体検出データを用意する。

条件 2：交通物体の状態記述について

本論文で定めた、動的走りやすさに影響する交通物体の種類は自動車、歩行者、バイク、自転車の 4 種類である。しかし、実際の運転シーンを確認すると交通する車を自動車とひとくくりにすることはできず、普通車、大型車、路上駐車などといった様々な車の状態を見ることができる。豊富な知識と経験を持つ人間にとっては上記のような状態は瞬時に判断可能であり、走りやすさに対して影響を持つ部分であるが、現段階の物体検出においてこれらの車の状態を識別することは非常に困難である。しかし、今後の検出器の精度向上や車線を認識して物体位置と車線との相対距離の取得などにより、交通物体の状態識別が可能となった時、走りやすさをより推定できるか否か調べることは重要である。そのため本論文では節 4.3 で述べたように、手入力による理想的な物体検出データについて、各交通物体の状態をラベルとして設定し、それぞれの状態を識別可能とした時にどの程度走りやすさ推定に効果を及ぼすかを確認する。

条件3：特徴量の抽出手法について

本実験では、運転シーン画像から物体検出により得られた交通物体データに対して特徴量を抽出し、動的走りやすさ影響量を推定する。そのため、適切に特徴量を抽出することで動的走りやすさ影響量が精度よく推定可能となる。この時、単純な特徴量として交通物体の種類ごとの出現個数のみを用いることが考えられる。それに対し、節4.4で述べたように、本研究では交通物体に対するドライバーの感覚を考慮し、任意の分割数による水平エリア分割及び放射状エリア分割により各交通物体の出現個数を場所毎に抽出する手法を考える。このエリア分割による特徴量抽出手法の有効性を示すため、任意の分割数での水平及び放射状エリア分割にて抽出した特徴量で動的走りやすさ影響量推定を行い、画像領域を分割しない出現個数情報での推定精度と比較して議論を行う。

条件4：統計的学習手法の選択について

各運転シーン画像の特徴量を算出したとき、特徴量のみから運転シーンの動的走りやすさ影響量を推定する。この時特徴量と走りやすさ点数との相関関係を統計的学習アプローチによりモデル化し、その推定モデルの精度を持って実験の結果とする。統計的学習手法としては節4.5、動的走りやすさ影響量のITS実用を考えた4クラスでの識別推定を、高性能な識別学習手法であるSVMと、局所性の確認に用いることができるk近傍法によって結果を議論する。

5.2 実験データ

本研究では、日本の公道を普通自動車で走行した際の車載カメラの映像データを元に、実験データとして車載カメラ画像を作製した。カメラを普通自動車の助手席の目線の高さから走行方向の消失点に中心が来るように取り付け、1920 × 1080ピクセル30fpsの動画を取得した。撮影条件としては天候不良による影響を避けるため、快晴の日の昼間に神奈川県二子玉川付近の複数の公道を、多様な運転シーンが撮影されるよう100分前後、計60km前後を走行し、運転シーンを撮影した。映像データから、交通物体によりドライバーの走りやすさに影響が出ていると思われる画像を、交通物体の出現頻度が分散するように180枚抽出した。この時、類似した画像の偏りを防ぐために他画像から10秒以上離れたものから抽出した。図5.2は実験データに用いた画像の例である。この画像群に対して、節3.2で定めた基準により交通物体による走りやすさへの影響量を、アノテーターの主観評価に基づいて点数化し、識別推定に用いるために量子化することで正解ラベルデータとする。この時、得られた180枚の実験データの動的走りやすさ影響クラスは表5.1のような分布となった。




図 5.2: 交通物体検出の例

表 5.1: 動的走りやすさ影響量の分布

走りやすさ影響クラス	画像数
-0 点クラス	22
-10 点クラス	77
-20 点クラス	55
-30 点クラス	26
合計	180

表 5.2: 物体検出の精度

交通物体	実際の出現個数	検出数	適合率	再現率	F 値
自動車	426	228	0.88	0.47	0.61
歩行者	404	211	0.43	0.23	0.30
バイク	32	6	0.50	0.09	0.16
自転車	116	31	0.65	0.17	0.27

5.2.1 物体検出データとその精度改善

交通シーンについて得られた 180 枚の画像群からは、節 4.2 で述べた DPM の統計学習に基づいて、自動車、歩行者、バイク、自転車の 4 種の交通物体を自動検出する。得られた物体検出データの精度を表 5.2 に示す。これは推定実験に用いる画像データ 180 枚について、実際に出現している交通物体の総数、自動検出された数、検出された中での正検出の割合、適合率、再現率、F 値をまとめたものである。ここで、適合率 (Precision) は検出したデータのうち正しく検出された正検出の割合、再現率 (Recall) は全正解物体データのうち正検出の割合である。F 値 (F-measure) は適合率と再現率により定義される、検出や検索などの性能を示す評価値であり、下式により定義される。

$$F = \frac{2}{\frac{1}{Recall} + \frac{1}{Precision}}. \quad (5.1)$$

DPM による各交通物体検出の適合率はいずれも 50% を切っており、特に対象画像の解像度が足りず物体検出に失敗している未検出の例が多い。また、特に自転車とバイクについて、各交通物体の向きや構造の多様性といった問題点により検出が出来ていない。ここで、本論文は画像解析により得られる交通物体の情報を用いて動的走りやすさ影響量が推定できるか否かが研究の大きな議題である。そのため検出誤差を含む物体検出データだけでなく、手入力により全ての交通物体を検出した交通物体情報を正解データとして用意する。手入力の正解データは、画像特徴による物体検出では未検出であった小さな交通物体や背景と多少同化している交通物体についてもラベルを振り、理想的な正解データとして得る。

更にここでは物体検出精度をより理想的な正解データに近づけるため、統計的学習手法による誤検出の削減を行う。具体的には誤検出と正検出の画像特徴量を統計的学習することにより両者の識別モデルを作成する。その識別モデルを持って走りやすさ推定実験のデータから誤検出を削減し、実験データの精度改善を図る。

i) 物体検出データ精度改善の手法

撮影された映像データの中から動的走りやすさ推定実験に用いる 180 枚以外の画像群に対し、DPM による交通物体検出を行い検出物体データを大量に得る。これら物体データの領域は、交通物体を内包する正検出の場合と内包していない誤検出の場合が存在するので、各交通物体について 1600 ほどの物体データを任意に選択し、それぞれについて正検出

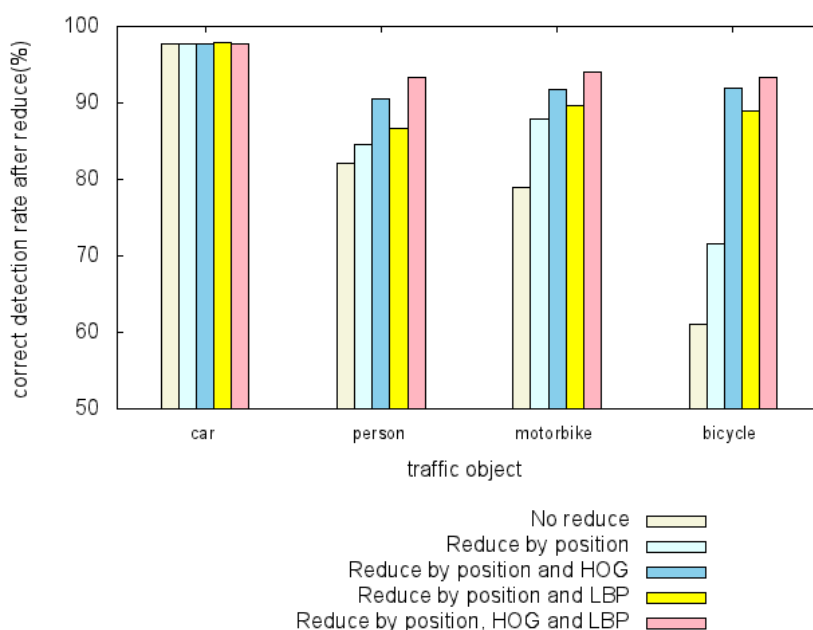


図 5.3: 各誤検出識別モデル適用による検出結果一致率

か誤検出かをラベルとして割り振る．これにより得られた誤検出／正検出データに対して，物体検出領域の画像特徴を算出し，両者の識別モデルを作成する．

誤検出識別モデル作成のための画像特徴として，物体データの位置情報，物体検出に用いた HOG 特徴及び画像の局所的な特徴を表現する LBP(Local Binary Pattern) 特徴 [35] を使用する．これらを正規化し，連結した画像特徴を用いて誤検出削減を行う．

ii) 物体検出データ精度改善の結果

用意した精度改善用実験データのうち，各交通物体それぞれ 400 データほどを学習データとして用い，交通物体領域の位置情報，HOG 特徴，及び LBP 特徴を元に SVM を用いて誤検出推定モデルを作成した．作成した誤検出識別推定モデルを学習データ以外の実験データに適用した時の，誤検出／正検出についての識別推定結果と正解ラベルとの一致率を図 5.3 に示す．次に，ここで作成した誤検出識別モデルを用いて，動的走りやすさ影響量推定に用いる実験データの誤検出を削減した．具体的には，全実験データに対して誤検出識別モデルを適用し，誤検出だと識別された実験データを削減し，残りのデータのみを推定実験に用いる．ここで，位置情報+HOG+LBP 特徴量を用いたモデルによる実験データ削減後の実験データは表 5.3 のようになった．削減前の表 5.2 と比較すると，検出問題の総合的な評価指標である F 値はわずかな差であるが減少傾向がみられる．図 5.4 左上及び右上に，削減モデルにより実験データの誤検出を削減した例を示す．

今回行ったデータ精度の改善は，正検出及び誤検出からなる物体検出データに対して誤検出を削減するモデルを用いたものである．これによって実験データの検出精度は上昇するが，未検出を含めた検出評価 F 値は減少することが分かった．後の走りやすさ推定実験

表 5.3: 物体検出データの誤検出削減誤の精度

交通物体	実際の出現個数	検出数	適合率	再現率	F 値
自動車	426	226	0.89	0.47	0.62
歩行者	404	190	0.46	0.22	0.29
バイク	32	4	0.50	0.06	0.11
自転車	116	24	0.75	0.15	0.26

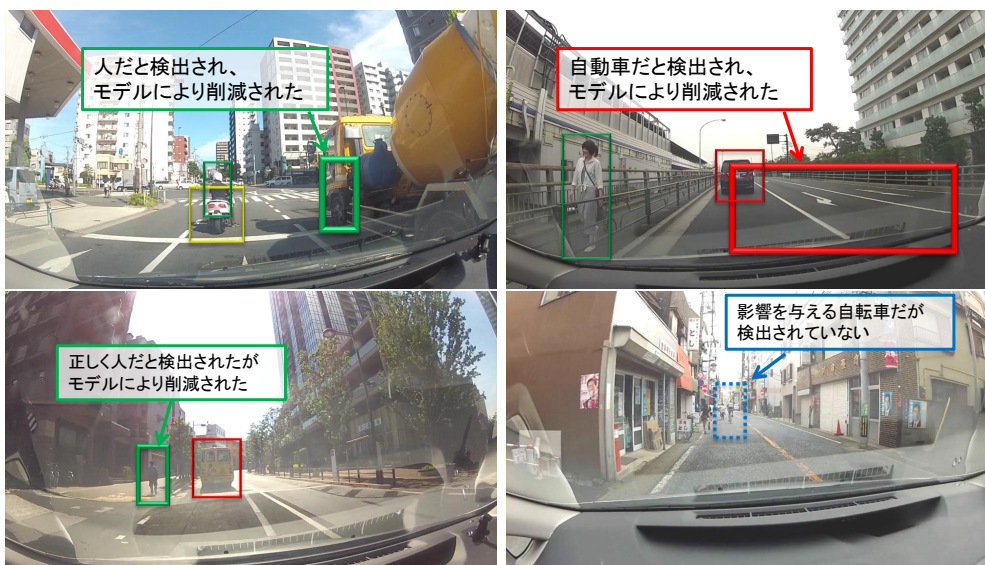


図 5.4: 誤検出削減の例

では、自動物体検出データや手入力の物体データと共に、誤検出削減した物体検出データによる推定実験も行う。ただし、削減できていない誤検出だけでなく、図 5.4 左下のように正しく検出できているものをモデルによって誤って削減してしまっているケースもあり、精度は向上したが物体の検出数を減少させている面もある。また、本実験でのデータ精度の改善は交通物体の検出情報を前提としたものであり、未検出の交通物体を考慮したものではない。図 5.4 右下のように検出されていない交通物体が走りやすさに影響を与えると考えられる例もあることを考えると、誤検出削減と共に未検出問題の解決が課題として挙げられる。

5.3 推定実験結果

これまでに説明したように、180 枚の車載カメラ画像について実験条件を可変としながら動的走りやすさ影響量の推定実験を行った。全データを学習用データと評価用データに分割すると、学習用データ及び評価用データが少なくなる。良い統計モデルを作成するには十分な量の学習データが必要であり、一方、評価用データが少ないとモデルの性能評価の正確性が不安である。従って、本実験では Leave-one-out 法 [36] による推定精度評価を

行った。Leave-one-out 法による統計学習は、1 サンプルのみを評価用データとし、他の全データを学習データとして推定モデルを作成した時、その1 サンプルの評価用データを適用させて正解との一致を調べる。これを全サンプルについて行い、その正解率を持って推定精度とする手法である。

本実験は可変とする実験条件が複数あり、全ての実験条件の組み合わせで比較して議論することは難しい。そのためここでは以下に挙げる実験条件をベースとし、各実験条件を単一で変化させたときの実験結果について議論する。

物体検出精度 …自動検出した結果の物体データ

交通物体の状態 …状態記述無しの車、歩行者、バイク、自転車の4種

特徴量抽出 …分割無しの出現個数

統計モデル学習 …SVMによる識別推定

また各実験条件下での実験結果について、分割無しでの出現個数を特徴量として用いた結果に加え、特徴量抽出手法を可変とした実験以外でも他分割手法を複数用い、その推定精度の平均を算出し、実験結果として報告する。これは、本実験が対象としている180個という実験データの個数では、本実験の多様な特徴量に対して定量性を得られるか保障できないため、多様な特徴量抽出での結果を平滑化することにより推定傾向を踏まえた議論をするためである。具体的には、分割無し、水平4分割、水平8分割、水平16分割、放射4分割、放射8分割、放射16分割の7種の実験での推定精度平均値を実験結果として示す。以下で各種実験条件について可変とした時の実験結果を述べる。

5.3.1 物体検出精度毎の推定精度

物体検出の精度を節5.2.1のように、画像特徴による自動検出データ、誤検出識別モデルにより誤検出を削減したデータ、誤検出の完全な削減を仮定した手入力による誤検出削減データ、誤検出や未検出の誤差を完全に無くした手入力による理想的交通物体データの4種類のデータを用意することで交通物体検出の精度を可変として走りやすさ推定実験を行った。また他の条件について、交通物体の状態記述は行わず、モデル学習手法としてはSVMによる識別推定を行い、特徴量抽出は分割無し及び複数分割手法の平均で結果を計算した。実験結果の推定精度として、推定した動的走りやすさ影響量クラスの正解値との一致率を図5.5に示す。

実験の結果、画像解析による物体検出精度、物体検出データに対して統計学習により誤検出削減を行った実験データ、手入力により誤検出を全て取り除いた物体検出データ、手入力により未検出問題も解決した理想的な物体データの順に動的走りやすさ影響量推定の精度が上昇することが分かった。物体検出の適用率及びF値の上昇につれて推定精度も上昇しているため、動的走りやすさ影響量は動的な交通物体の検出精度に依存したドライバーの感覚量だと言える。そのため、動的走りやすさ影響量の推定に対して運転シーン画像解析により交通物体の特徴量を取り出す本手法は有効なアプローチだと言える。ここで、各特徴量抽出手法での平均推定精度を見ると、画像解析による物体検出データで42.9%、誤

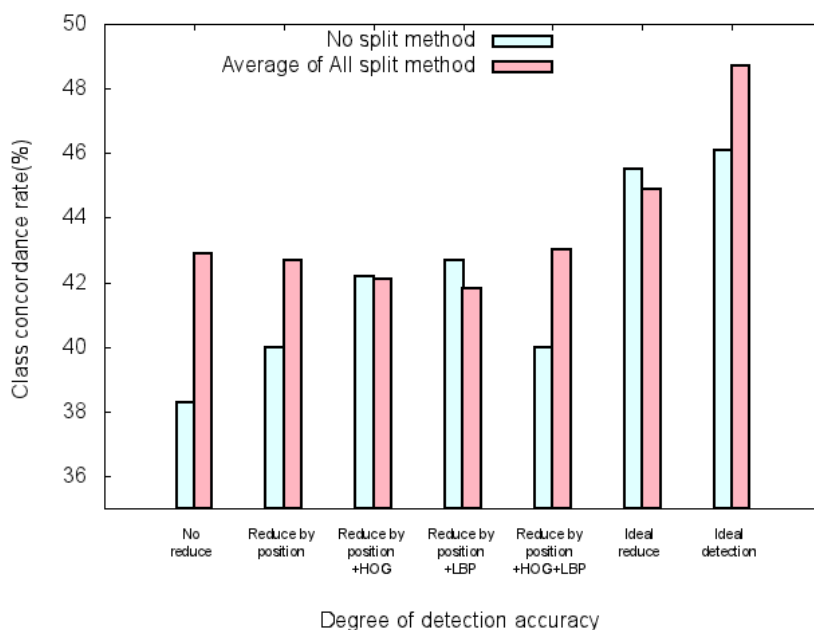


図 5.5: 検出精度を可変とした時の動的走りやすさ影響クラス推定一致率

検出削減を行ったデータで 43.0% , 誤検出を理想的に削減したデータで 44.9% , 誤検出及び未検出問題を解決した理想的な物体データで 48.7% であり, 未検出を解決することによる推定精度の向上が大きいことが分かる. これは, 未検出問題の解決により検出物体数が増し, 推定に有効な特徴量を統計的に捉えることができ推定性能を向上させているためと考えられる.

ここで, 物体検出の精度について表 5.2 を見ると, 全交通物体に対して適合率が再現率を上回っている. 検出問題の総合的評価指標である F 値を向上させるためには, 適合率及び再現率双方の向上が必要である. しかし, 一般的に検出問題において一方を向上させようとするともう一方の数値は低下してしまう傾向にある [37]. これと式 5.1 における適合率と再現率の等価性を考えると, どちらか一方が優れている検出に比べ, 両者のバランスの良い検出の評価が高いことが分かる. 本実験により動的走りやすさ影響量の推定精度は物体検出の F 値への依存性が強いと考えられるため, 誤検出削減による適合率向上と比べ未検出問題の解決による再現率向上が重要であると考えられる. そのため, 誤検出が増加してしまうことも考えられるが, 物体検出時の物体尤度閾値を低下させ多くの交通物体を検出し, その後に誤検出削減を行う, といった推定精度改善の方針が考えられる.

5.3.2 交通物体の状態区分毎の推定精度

検出誤差を無くした手入力による理想的交通物体データに対して, 交通物体の状態を節 4.3 のように付与した. これを用いて表 4.2 に示す交通物体の状態区分を行い, それぞれの区分に対して走りやすさ影響量の推定実験を行った. 他の実験条件については, 統計的学習手法として SVM による識別推定を行い, 特徴量抽出は分割無し及び複数分割手法の平




図 5.6: 交通物体の状態区分を可変とした時の動的走りやすさ影響クラス推定一致率

均の結果となる推定精度を計算した。実験結果の推定精度として、推定した走りやすさ影響量クラスの正解値との一致率を図 5.6 に示す。

実験の結果、交通物体の状態を詳細に表現するにつれて、動的走りやすさ影響クラスの推定が正確に行われることが分かった。ここで、本実験は手入力による理想的な交通物体データに対して、手入力による交通物体の状態を付与したものをを用いたものであり、実際の車載カメラ画像解析による動的走りやすさ影響量の推定ではない。そのため、本実験で前提とした車線やガードレール情報の取得などの技術的な課題解決が必要であるが、動的走りやすさ影響量推定の指針として、交通物体の状態を詳細に記述することは有効に機能する、ということが言える。実験結果を詳細に見ると、区分 C での推定実験においてのみ分割無し時の推定精度が分割手法の平均値を上回っている。区分 C とは、交通物体の位置に応じたそれぞれの危険性を表現した区分である。そのため、特徴量の分割手法の選定理由である各交通物体の危険性毎に特徴成分を構成する意図と重なったために、分割無しでの推定精度が上回っている、と考えることができる。これは逆に、交通物体の危険性毎に特徴成分を構成することの有効性を示しているとも見て取れる。ここで、これらの状態ラベルの設定は、実験データである 180 枚の車載カメラ画像について設定したものであり、考えうる全ての運転シーンに対応したものではない。例えば 180 枚の車載カメラ画像にはタクシーが出現しておらず、タクシーによってドライバーが受ける走りやすさ影響量を推定することは出来ていない。そのため、交通物体の状態をより詳細に記述するために、多くの実験データを更に幅広い交通物体の状態について表現できるように取得する必要がある。

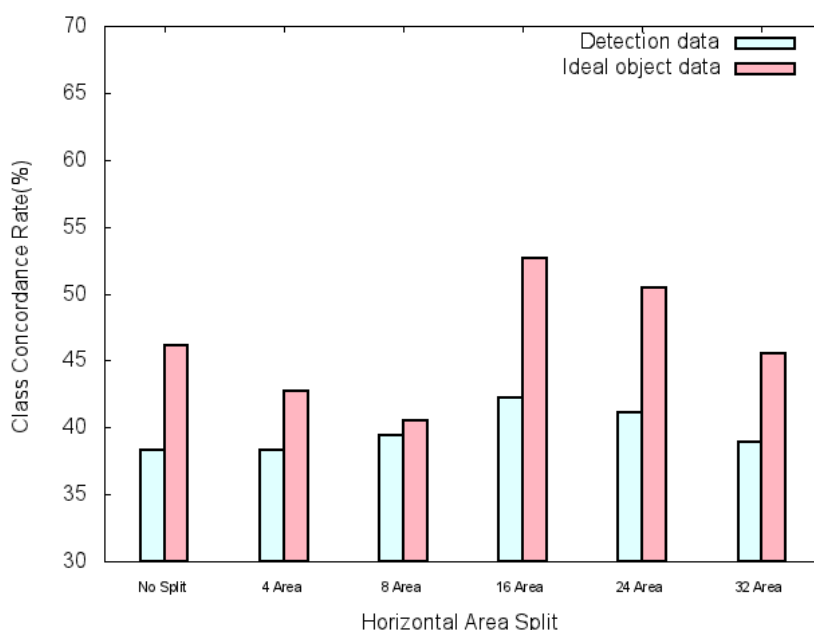


図 5.7: 分割幅を可変とした水平エリア分割時の走りやすさ影響クラス推定精度

5.3.3 特徴量抽出手法毎の推定精度

物体検出などにより得られた交通物体データに対して、節 4.4 で述べた特徴量抽出を多様に行い、水平エリア分割及び放射状エリア分割手法でそれぞれの特徴量を抽出し、動的走りやすさ影響量の推定を行った。他の条件について、交通物体の検出精度に自動検出結果及び理想的な交通物体データを用い、交通物体の状態による区分は行わずに、SVMによる識別推定を行った。実験結果として、識別推定時の走りやすさ影響クラスの正解クラスとの一致率を、水平エリア分割の分割幅を可変としたものを図 5.7 に、放射状エリア分割の分割角度を可変としたものを図 5.8 に示す。

実験の結果、分割を行わない推定時の物体検出精度と比べ、水平エリア分割による特徴抽出時、及び放射状エリア分割による特徴抽出時でそれぞれ上回る推定精度が得られた。ただし、放射状エリア分割手法では分割無し時の推定精度を全て上回っているが、水平エリア分割手法では分割無し時の推定精度を下回る推定性能のものも見られる。各種分割手法の理想物体データ時の推定精度平均を計算すると、分割無し時が 46.1%、各水平エリア分割の平均が 46.4%、各放射状エリア分割の平均が 52.6% となり、放射状エリア分割手法が動的走りやすさ影響量の推定に有効であることが示される。ここで、各分割手法の選定理由は、水平エリア分割が交通物体の奥行方向の距離感の表現、放射状エリア分割が交通物体の車線との距離感の表現であった。これを考えると、交通物体の車線との距離感によって、ドライバーは走りやすさに強く影響を受けていると言える。これは交通物体の状態記述による動的走りやすさ影響量の推定時の結果と合致し、交通物体の危険性に応じて出現数を特徴成分として構成することが動的走りやすさ影響量の推定に有効であるという知見が得られる。

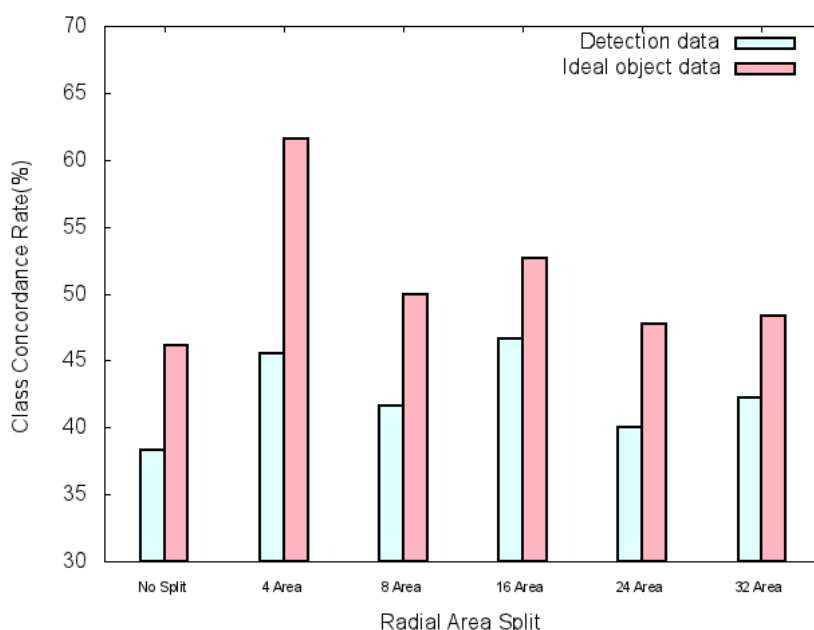


図 5.8: 分割幅を可変とした放射状エリア分割時の走りやすさ影響クラス推定精度

5.3.4 モデル学習手法毎の推定精度

動的走りやすさ影響量の統計的学習手法として、節 4.5 で述べたよう SVM 及び k 近傍法による識別推定を行った。他の実験条件については、交通物体の検出精度は理想的な交通物体データを用い、交通物体の状態による区分は行わず、特徴量抽出は分割無し及び複数分割手法の平均で結果となる推定精度を計算した。実験結果として、識別推定時の走りやすさ影響クラスの正解クラスとの一致率を図 5.9 に示す。ここで、k 近傍法での探索距離 k は k=11 の時の結果であり、これは k=1,3,5,7,11,15,21 で実験を施行し、最も高い性能であった k=11 を用いている。

実験の結果、ランダムによる 4 クラス分類では正解率が 25.0% であるのに対し、SVM 及び k 近傍法での動的走りやすさ影響クラス推定の正解率は分割無しの場合 46.1% 及び 51.6% と、高い推定精度を記録している。このことから、動的走りやすさ影響量の推定に対する統計的な識別学習の有効性が示された。また、分割無し時での各統計学習の推定精度を比較したとき、SVM と比べて k 近傍法での推定が性能よく働いている。k 近傍法は局所的な特徴量構造を重視する推定手法であるため、動的走りやすさ影響量は出現個数情報の類似したものとの相関関係が強いとすることができる。

5.4 考察

物体の検出精度、物体の状態記述、特徴量の設定方法といった各実験条件を可変として動的走りやすさ影響量の推定実験を行った。その結果、物体検出の精度向上、交通物体の状態記述、及びエリア分割による特徴量抽出が動的走りやすさ影響量の推定に対して有効

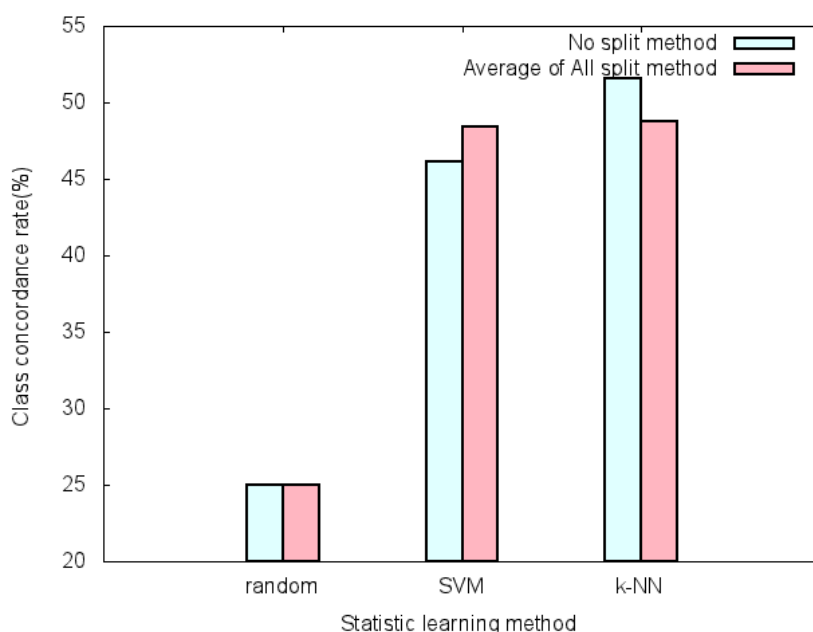


図 5.9: 統計的学習手法を可変とした時の走りやすさ影響クラス推定精度

に働くことが確認できた。特に、物体の検出精度向上が動的走りやすさ影響クラス推定の精度を向上させていることから、車載カメラ画像解析により交通物体を検出する本手法への有効性が示された。また、歩行者の飛出しの危険性など物体の状態を記述すること、及び交通物体の車線との距離感を表現する放射状エリア分割での特徴量抽出手法によって推定精度が向上していることから、交通物体の危険度合に応じて特徴量を構成することが動的走りやすさ影響量の推定に有効であると言える。

これについて、図 5.10 に、交通物体による動的走りやすさの影響クラスごとに、画像全体で出現する交通物体の個数平均を示す。これをみると影響クラスの程度と交通物体の出現個数そのものについて相関が見られる。つまり、画像全体に出現する交通物体の個数のみによって、ある程度は動的走りやすさの影響クラスを推定できている、と考察できる。しかし、ここで表 5.4 に示した、各エリア分割時の動的走りやすさの各影響クラス推定の混合行列を見る。これは動的走りやすさ影響クラスの画像それぞれが、どのクラスに推定されたかの割合を表すものであり、これを見ると分割無しの特徴抽出時に行えていない-0点影響クラスへの推定が、放射2分割の特徴抽出により可能となっていることが分かる。また分割手法を用いることにより、分割無しに比べて-20点影響クラスの画像が正しく推定されていることも読み取れ、交通の安全面で重要となる動的走りやすさ影響量の大きいクラスにおいて推定精度が向上していることが分かる。これらのことから、本手法であるエリア分割による特徴量設定法は、動的走りやすさ影響量の推定に有用な指針であると言える。

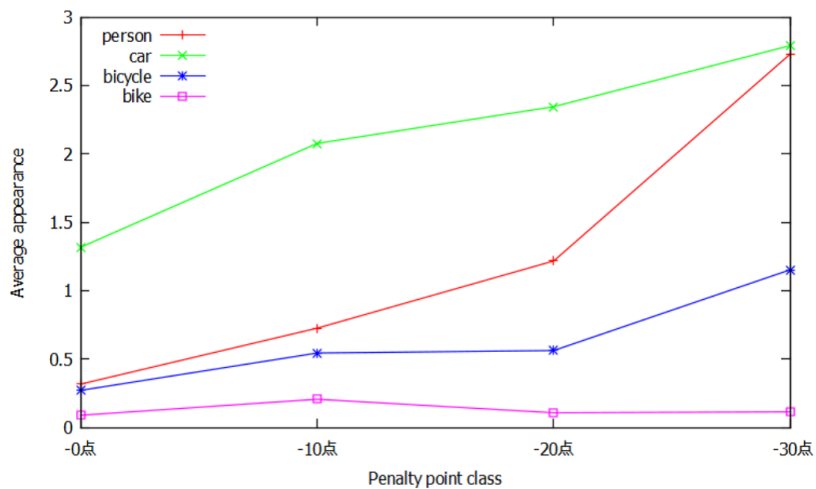


図 5.10: 動的走りやすさ影響クラス毎の交通物体の出現数平均

表 5.4: エリア分割手法での各走りやすさ影響クラスへの混合行列

No split

	0点	10点	20点	30点
0点	0	81.8	13.6	4.5
10点	0	85.7	6.4	7.7
20点	0	69.0	20.0	10.9
30点	0	11.5	38.4	50.0

8 horizontal split

	0点	10点	20点	30点
0点	0	90.9	9.0	0
10点	0	81.8	14.2	3.8
20点	0	43.6	43.6	12.7
30点	0	15.3	34.6	50.0

2 radial split

	0点	10点	20点	30点
0点	59.0	40.9	0	0
10点	9.0	72.7	15.5	2.5
20点	5.4	52.5	34.5	7.2
30点	0	7.69	26.9	65.3

第6章

まとめ

6.1 結論

本研究では、実際の運転シーンにおけるドライバーの感覚に応じた動的な走りやすさをITSに実用することを踏まえ、運転シーンについての交通物体による動的な走りやすさへの影響量を定義し、動的走りやすさ影響量の推定手法を提案した。本手法では、運転シーンの車載カメラ画像から交通物体を検出し、物体データから特徴量を抽出する。この特徴量を用いた統計的学習手法により、該当する運転シーンの動的走りやすさ影響量の推定実験を行い評価した。その際、評価のために物体検出精度、交通物体の状態記述、特徴量抽出手法、統計的学習手法、といった実験条件を多様に変えて実験を行った。その結果、動的走りやすさ影響量の推定に対して交通物体検出という画像処理的アプローチが有効であり、より詳細な交通物体の状態記述により推定精度が上昇すること、及びエリア分割による交通物体の計上に基づいた統計的学習が有効に働いていることを確認できた。特に、動的走りやすさに影響が大きいと考えられる、交通物体の自車との距離及び車道との距離を、水平エリア分割と放射エリア分割による特徴抽出法によって表現したが、その結果、特に放射状エリア分割において動的走りやすさ影響量を精度よく推定できていた。また、交通物体の安全性を示す状態記述も動的走りやすさ影響量推定に有効であったことを合わせて考えると、動的走りやすさ影響量の推定に対して交通物体の危険度合に応じて特徴量を設定することが有効であるという知見が得られた。

6.2 課題と展望

本研究により、動的走りやすさ影響量の推定に対して、車載カメラ画像解析による物体検出のアプローチ、及び各交通物体を場所情報などで危険度合により分類して考える手法の有効性を示した。

しかし、十分に理想的な物体データを用いた推定実験の結果である4クラスの動的走りやすさ影響クラス識別の精度が60%ほどであるのに対し、自動検出データを用いた場合の識別精度は40%ほどである。これは、ITSとして動的走りやすさ影響量を活用しようという場合に実用性に足るとは言えず、更なる精度が必要である。そのため、今後はこの画像解析での物体検出データを用いた推定精度の向上が課題として挙げられる。

各種実験条件を可変とした際の結果を考察することにより、推定精度向上の方針を述べる事ができる。まず、物体検出の精度を向上させ、より理想的な物体データに近づけることで動的走りやすさ影響量の推定精度を向上させられる。現段階での物体検出の問題は、ドライバーは遠くの小さな交通物体によっても走りやすさに影響を受けるが対象領域の解像度が足りずに検出できていないことが大きい。そこで、解像度を向上させるもしくは低解像度においても検出性能が得られる特徴量を用いる、などの改善案が考えられる。また、物体の状態を理想的な物体データに付与することで推定精度が上昇していることから、交通物体の状態を画像解析によって識別推定することが精度改善に有効である。方針としては交通物体の向き、位置、大きさの情報、及び運転シーンの運転方向と車線を検出し、これらの情報を複合的に考えることで交通物体がどの位置にいるのか、どの方向に進むのか、どの行動をとるのかをある程度推定することが考えられる。加えて歩道のガードレールや柵を検出することで交通物体の危険度合の表現が可能になるだろう。続いて今回提案したエリア分割手法による特徴量抽出手法には、定性的な動的走りやすさ影響量との相関性は見いだせないものの、分割手法によって有効に機能しているものが多い。そのため、有効な分割手法を組み合わせた複合的なエリア分割などを考案することで、より精度良く動的走りやすさ影響量が推定されると期待できる。

また、本研究は1枚の画像に対する動的走りやすさ影響量の推定を行った。しかし、動的走りやすさに対して影響のある、交通物体の動きの情報や、各道路の中長期的な走りやすさなど、車載カメラ映像を画像単位でなく動画として扱うことで、自車の走行速度や向きなどと相対的に考えて推定が可能となる部分も大きい。更に本研究で定義した動的走りやすさ影響量は、実用性を考慮すると動画情報を用いることで、リアルタイムな自動車の参加型センシングなどにより有効な活用が期待できる。

その他、これは根本的な問題でもあるのだが、本研究で定義している動的走りやすさ影響量はドライバーの感覚に基づいて設定している感覚量であり、そのためにドライバーそれぞれの個人的感覚に依存してしまい、ドライバーの運転経験や性格、判断などにより同じ運転シーンでも異なる量となってしまう。そのため、本研究での定義に対して更なる考案を進め、より一般性の高い動的走りやすさ影響量を定義することも、本研究の今度にとって重要であると言える。更に、動的走りやすさ影響量を構成する交通要因は非常に多岐に渡り、本研究での定義によってドライバーの感覚量を表現できていない部分もあると思われる。例えば、交通シーンの見通しなどは車載カメラ画像からの定量的な取得推定が難しい問題であるが、動的走りやすさに対して影響する問題である。そのため、本研究での交通物体検出によるアプローチの他に、全体像を把握する画像解析なども重要になってくると思われる。

謝辞

本研究を行うにあたり、非常に多くの人のお世話になりました。

佐藤洋一教授には指導教官として研究のテーマを示したいただき、また研究に対して多様なアドバイスをくださり、研究者として大事な意識や、本質を筋道立てて常に考える大切さを学ばせていただきました。研究だけに留まらず、私事についても丁寧に相談に乗っていただけたことは、強く心の支えとなりました。佐藤先生の下で過ごすことができたこの有意義な2年間は大変貴重な時間であり、今振り返っても光栄な思いに身を包まれます。これからの人生においても、その考え方や生き方を大切な指針にしたいと思います。本当にありがとうございました。

株式会社トヨタ IT 開発センターのNaiwala P. Chandrasiriさんを初めとする多くの方には、共同研究者として実験に用いるデータの提供や、会議の場での意見交換をしてくださり、またシステム構築の目線から貴重なご助言を数多く頂きましたことを、誠に感謝いたします。

本研究室特任助教の松川徹さんには、本研究について非常に多くの部分でアドバイスをいただき、いかなる時でも丁寧に快く相談に乗ってくださり、大変深くお礼を申し上げます。研究の相談、執筆の細かな添削や、技術的な指導など、この2年間常にお世話になりました。研究に対する真摯な態度を身近で学ぶことができ、今後の人生に活かしたいと思います。誠にありがとうございました。

本研究室特任助教の菅野裕介さんには、その広く深い知見を学ばせていただきました。幅の広い学術についてだけでなく、日頃の生活の中でも菅野さんの言葉に考えさせられることがあり、自身の甘い部分について見つめ直すことができました。誠にありがとうございました。

また、この大学院の2年間を共に過ごしてきた多くの友人や、研究室の皆様、そして家族にも、深く感謝を申し上げます。日頃の研究生活を、楽しく有意義に過ごすことができたのは、周囲の人々との時間のおかげであります。辛い気持ちや楽しい時間を共有でき、話し合い、相談にも乗っていただき、気持ちの良い人々に恵まれた生活を送れたことは、何よりの経験です。

とても多くの人々に支えられ、本論文を完成させることができました。共に時間を過ごすことができた全ての皆様に、この場を借りて深くお礼を申し上げます。

2014年2月
寺井 真

参考文献

- [1] S. An, B. H. Lee, and D. R. Shin, “A Survey of Intelligent Transportation Systems,” Computational Intelligence, Communication Systems and Networks (CICSyN), 2011 Third International Conference on. IEEE, 2011.
- [2] 服部彰, 大上健一, “ドライバーモニター付きプリクラッシュセーフティシステム,” JSAE Symposium, no.1-7, 2007.
- [3] S. Tokoro, *et al.*, “Electronically scanned millimeter-wave radar for pre-crash safety and adaptive cruise control system,” Intelligent Vehicles Symposium, 2003. Proceedings. IEEE. IEEE, 2003.
- [4] Z. Sun, *et al.*, “A real-time precrash vehicle detection system,” Applications of Computer Vision, 2002.(WACV 2002). Proceedings. Sixth IEEE Workshop on. IEEE, 2002.
- [5] T. Aotani, “Research and development of driving safety support systems,” 2002 IEEE Intelligent Vehicles Symposium, pp.1792-1797, 2003.
- [6] J. Levinson, *et al.*, “Towards fully autonomous driving: Systems and algorithms,” Intelligent Vehicles Symposium (IV), 2011 IEEE. IEEE, 2011.
- [7] K. Akaho, *et al.*, “A study and evaluation on route guidance of a car navigation system based on augmented reality,” Human-Computer Interaction. Towards Mobile and Intelligent Interaction Environments. Springer Berlin Heidelberg, 357-366, 2011.
- [8] 奥谷正, 井坪慎二, 橋本浩良, 前川友宏, “走りやすさマップデータを用いた日本の道路ネットワークの現状分析,” 土木計画学研究・講演集, 社団法人土木学会. Vol.35. pp.90-92. 2007.
- [9] S. Eichler, C. Schroth, and J. Eberspacher, “Car-to-car communication,” VDE-Kongress 2006. VDE VERLAG GmbH, 2006.
- [10] J. A. Burke, *et al.*, “Participatory sensing,” 2006.
- [11] M. Oren, *et al.*, “Pedestrian detection using wavelet templates,” Computer Vision and Pattern Recognition, 1997. Proceedings., 1997 IEEE Computer Society Conference on. IEEE, 1997.
- [12] D. M. Gavrila, “Pedestrian detection from a moving vehicle,” Computer Vision?ECCV 2000. Springer Berlin Heidelberg, 37-49, 2000.
- [13] K. Doman, *et al.*, “Estimation of traffic sign visibility toward smart driver assistance,” Intelligent Vehicles Symposium (IV), 2010 IEEE. IEEE, 2010.

- [14] S. Houben, *et al.*, “Detection of traffic signs in real-world images: The German Traffic Sign Detection Benchmark,” International Joint Conference on Neural Networks (submitted). 2013.
- [15] M. Bertozzi, and A. Broggi, “GOLD: A parallel real-time stereo vision system for generic obstacle and lane detection,” Image Processing, IEEE Transactions on 7.1 62-81, 1998.
- [16] C. Fan, J. Xu, and S. Di, “Lane Detection Based on Machine Learning Algorithm,” TELKOMNIKA Indonesian Journal of Electrical Engineering 12.2 1403-1409, 2014.
- [17] D.Engel, C.Curio, “Pedestrian Detectability: Predicting Human Perception Performance with Mashine Vision,” Proc.2011, IEEE Intelligent Vehicles Symposium, pp.429–435, June 2011.
- [18] H.Drucker, C.J.C.Burges, *et al.*, “Support vector regression machines,” In Advances in Neural Information Processing Systems, pp155–161, MIT Press, 1997.
- [19] F.Kimura, T.Takahashi, Y.Mekada *et al.*, “Measurement of Visibility Conditions toward Smart Driver Assistance for Traffic Signals”, 2007 IEEE Intelligent Vehicles Symposium, pp.636-641, 2007.
- [20] P.Siegmann, *et al.*, “Automatic evaluation of traffic sign visibility using SVM recognition methods,” Proc.5th WSEAS Int. Conf. on Signal Processing, Computational Geometry and Artificial Vision, pp170–175, Sept, 2005.
- [21] L.Simon, J-P.tarel, and R.Bremond, “Alerting the drivers about road signs with poor visual saliency,” Proc. 2009 IEEE Intelligent Vehicles Symposium, pp.48–53, June 2009.
- [22] A.Bosch, A.Zisserman, and X.Munoz, “Representing shape with a spatial pyramid kernel,” In Conference on Image and Video Retrieval, pp.401–408, ACM, 2007.
- [23] 道満恵介, 出口大輔, 他, “コントラスト特徴とアピアランス特徴の統合による道路標識の視認性推定,” 電子情報通信学会論文誌 D, Vol.195–D, No.1, pp.122–130, 2012.
- [24] L.Itti, C.Koch, and E.Niebur, “A model of saliency-based visual attention for rapid scene analysis,” IEEE Transactions on Pattern Analysis and Mashine Intelligence (PAMI), Vol.20, No.11, pp.1254–1259, 1998.
- [25] N. Dalal, B.Triggs, “Histograms of Oriented Gradients for Human Detection,” Proc. IEEE Intl. Conf. CVPR, pp.886-893, 2005.
- [26] P.F. Felzenszwalb, *et al.*, “Object detection with discriminatively trained part-based models,” IEEE Transactions on Pattern Analysis and Machine Intelligence, vol.32, no.9, pp.1627–1645, 2010.
- [27] M. Enzweiler, D. M. Gavrila, “Monocular Pedestrian Detection Survey and Experiments,” IEEE Transactions on Pattern Analysis and Machine Intelligence, vol.31, no.12, pp.2179–2195, 2009.
- [28] C. Cortes, and V. Vapnik, “Support-vector networks,” Machine learning 20.3 (1995): 273–297, 1995.

参考文献

- [29] T. Cover, and P. Hart, “Nearest neighbor pattern classification.” *Information Theory, IEEE Transactions on* 13.1, pp.21–27, 1967.
- [30] C.M. ビショップ, “パターン認識と機械学習 ベイズ理論による統計的予測,” Springer, 2007.
- [31] C.C. Chang, C.J.Lin, “LIBSVM a library for support vector machine,” <http://www.ces.ntu.edu.tw/cjlin/livsvm> , 2001.
- [32] C.W.Hsu, C.C.Chang, C.J.Lin, “A Practical Guide to Support Vector Classification,” <http://www.csie.ntu.edu.tw/~cjlin/papers/guide/guide.pdf> , 2003.
- [33] C.W.Hsu, C.J.Lin, “A comparison of Methods for Multi-class Support Vector Machine,” 2002 *IEEE Transaction on Neural Networks*, Vol.3, No.2n pp.415-425, 2002.
- [34] K.Fukunaga, “Introduction to statistical pattern recognition (second edition),” Academic press, New York, 1990.
- [35] T. Ojala, M. Pietikainen, and T. Maenpaa, “Multiresolution gray-scale and rotation invariant texture classification with local binary patterns,” *Pattern Analysis and Machine Intelligence, IEEE Transactions on* 24.7 (2002): 971-987, 2002.
- [36] M. Kearns, and D. Ron, “Algorithmic stability and sanity-check bounds for leave-one-out cross-validation,” *Neural Computation* 11.6 (1999): 1427-1453, 1999.
- [37] C. Goutte, and E. Gaussier, “A probabilistic interpretation of precision, recall and F-score, with implication for evaluation,” *Advances in Information Retrieval. Springer Berlin Heidelberg*, 345-359, 2005.

発表文献

- [1] 寺井真, 松川徹, 佐藤洋一 “車載カメラ画像解析による運転時の走りやすさ推定”, 画像の認識・理解シンポジウム, 2013-08