

車両下影に基づく先行車両検出に関する研究

令和2年6月

関 弘 翔

- 目次 -

第1章	序論.....	1
1.1	背景	1
1.2	関連研究と本論文の目的.....	5
1.3	本論文の構成.....	10
	文献	12
第2章	白線エッジ特徴を考慮したエッジ重畳による道路白線抽出	16
2.1	白線抽出の関連研究と本研究の位置づけ	16
2.2	白線エッジ特徴を考慮したエッジ重畳による道路白線抽出概要	18
2.3	白線エッジ特徴を利用したエッジ抽出.....	20
2.4	リングバッファを用いたエッジ重畳.....	30
2.5	連結画素走査.....	35
2.6	白線抽出実験.....	39
2.7	実験環境外への対応と展望.....	51
2.8	まとめ	55
	文献	55
第3章	車両下影に着目した車両識別による先行車両検出.....	57
3.1	影に着目した先行車両検出の関連研究と本研究の位置づけ	57
3.2	車両下影に着目した車両識別による先行車両検出の概要	60
3.3	車両下影抽出.....	60
3.4	車両識別.....	65
3.5	先行車両検出実験.....	84
3.6	まとめ	90
	文献	91
第4章	Particle Filter による影らしさと車両らしさを考慮した車両下影追跡	94
4.1	物体追跡の関連研究と本研究の位置づけ	94
4.2	影を利用した先行車両追跡の関連研究と本研究の位置づけ	96
4.3	Particle Filter による影らしさと車両らしさを考慮した車両下影追跡の概要 ..	98
4.4	影らしさを表す尤度.....	100
4.5	車両らしさを表す尤度.....	105
4.6	車両追跡実験.....	110
4.7	まとめ	119
	文献	119

第5章	結論.....	122
5.1	本論文の成果.....	122
5.2	今後の課題.....	124
謝	辞.....	125
著者発表論文	126

- 目次 -

図 1.1	交通事故発生状況の推移.....	2
図 1.2	平成 30 年における交通事故の事故類型別割合	2
図 1.3	平成 30 年における交通事故の事故要因別割合	2
図 1.4	タイヤを用いた車間距離推定の概要図.....	6
図 1.5	車両下影を用いた車間距離推定の概要図.....	9
図 1.6	先行車両検出システムの流れ.....	10
図 2.1	エッジ重畳の概念.....	19
図 2.2	本論文で提案する白線抽出処理の流れ.....	19
図 2.3	Sobel フィルタ	21
図 2.4	道路標示を含む入力画像.....	22
図 2.5	道路標示を含む入力画像からのエッジ強度抽出.....	22
図 2.6	エッジの量子化方向.....	23
図 2.7	16 方向で量子化し色分けしたエッジ画像.....	23
図 2.8	限定するエッジ方向.....	23
図 2.9	白線エッジの方向特徴を利用したエッジ抽出.....	23
図 2.10	曲率半径の大きなカーブシーン例（先行車両が 80m 遠方付近に存在）	24
図 2.11	曲率半径の小さなカーブシーンの例.....	24
図 2.12	正負のピーク情報を反映させたエッジ抽出.....	25
図 2.13	白線エッジのピーク特徴を利用したエッジ選別の概要	26
図 2.14	白線エッジのピーク特徴を利用したエッジ選別.....	27
図 2.15	構造化要素の例.....	27
図 2.16	膨張処理の例.....	28
図 2.17	収縮処理の例.....	28
図 2.18	エッジ選別後に 3×3 の square を用いた収縮処理	29
図 2.19	構造化要素 Line	29
図 2.20	白線エッジの方向特性を利用したエッジ補正.....	30
図 2.21	エッジ過重畳例.....	30
図 2.22	リングバッファ構造.....	31
図 2.23	リングバッファを用いたエッジ重畳の概念図：重畳フレーム数 50 の例.....	32
図 2.24	走行速度に対する破線間隔を補うために必要な走行フレーム数	33
図 2.25	走行速度に対する破線 1 周期分を補うために必要な走行フレーム数.....	34
図 2.26	連結画素走査の概念図.....	36
図 2.27	実際の白線とずれが生じた連結画素走査の例.....	37
図 2.28	直線近似に用いるエッジ点の探索範囲.....	37

図 2.29	最小二乗法（左）と主成分分析（右）	38
図 2.30	連結画素走査を用いた直線近似	38
図 2.31	高速道路昼晴天シーンにおける白線抽出結果例	42
図 2.32	高速道路昼晴天シーンにおけるフレーム毎の平均 x 座標誤差の推移	43
図 2.33	一般道夜雨天シーンにおける白線抽出結果例	45
図 2.34	一般道夜雨天シーンにおけるフレーム毎の平均 x 座標誤差の推移	46
図 2.35	一般道昼雨天シーンにおける白線抽出結果例	48
図 2.36	一般道昼雨天シーンにおけるフレーム毎の平均 x 座標誤差の推移	49
図 2.37	黄色線での白線抽出	51
図 2.38	横断歩道での白線抽出 1	52
図 2.39	横断歩道での白線抽出 2	52
図 2.40	上り坂での白線抽出例	53
図 2.41	下り坂での白線抽出例	53
図 2.42	積雪時の白線抽出例	54
図 3.1	車両下影に着目した車両識別による先行車両検出の流れ	60
図 3.2	影候補抽出の画像例	61
図 3.3	車両下影候補抽出の画像例	63
図 3.4	影候補除去の概念図	64
図 3.5	影候補除去の画像例	64
図 3.6	車両下影抽出の問題点	65
図 3.7	学習サンプルの画像例	68
図 3.8	データ拡張の例	68
図 3.9	確率密度分布の例	69
図 3.10	Haar-like 特徴量の形状	74
図 3.11	EOH 特徴量算出のためのエッジ方向算出	75
図 3.12	エッジ方向ヒストグラム特徴量	76
図 3.13	有力方向特徴量	76
図 3.14	左右対称性特徴量	77
図 3.15	セル単位のエッジ方向ヒストグラム	78
図 3.16	Integral Image（積分画像）の概念図	80
図 3.17	車両・非車両の識別の画像例	81
図 3.18	車両識別結果の統合例	81
図 3.19	車両下影候補領域の定義	82
図 3.20	車両識別器適用のイメージ	83
図 3.21	全手法での正検出例（高速道路昼晴天）	88
図 3.22	車両識別の成功による提案手法の正検出例（高速道路昼晴天）	88

図 3.23	車両識別の失敗による提案手法の誤検出例（高速道路昼晴天）	88
図 3.24	全手法での正検出例（一般道夜雨天）	90
図 3.25	車両識別の成功による提案手法の正検出例（一般道夜雨天）	90
図 3.26	車両識別の失敗による提案手法の誤検出例（一般道夜雨天）	90
図 4.1	サンプリング手法	95
図 4.2	提案する車両下影追跡の概念図	99
図 4.3	ヒストグラム平坦化の例	101
図 4.4	KCF の概念図	105
図 4.5	尤度算出例	109
図 4.6	高速道路昼晴天シーンの評価曲線	112
図 4.7	高速道路昼晴天シーンの追跡結果例	113
図 4.8	一般道夜雨天シーンの評価曲線	114
図 4.9	一般道夜雨天シーンの追跡結果例	115
図 4.10	一般道夕方逆光シーンにおける評価曲線	116
図 4.11	一般道夕方逆光シーンにおける追跡結果例	117

- 表目次 -

表 1.1	運転自動化レベルの概要	4
表 2.1	白線エッジのピーク特徴を利用したエッジ選別の処理手順	26
表 2.2	リングバッファを用いたエッジ重畳の処理手順	31
表 2.3	破線状の白線の寸法	33
表 2.4	連結画素走査の処理手順	36
表 2.5	提案手法と比較手法	40
表 2.6	高速道路昼晴天シーンにおける実験結果	42
表 2.7	一般道夜雨天シーンにおける実験結果	45
表 2.8	一般道昼雨天シーンにおける実験結果	48
表 2.9	実験シーンを通した実験結果	50
表 3.1	Real AdaBoost のアルゴリズム	67
表 3.2	高速道路昼晴天シーンの実験結果	87
表 3.3	一般道夜雨天シーンの実験結果	89
表 4.1	Particle Filter アルゴリズム ^[4-6]	98
表 4.2	高速道路昼晴天シーンの実験結果	112
表 4.3	一般道夜雨天シーンの実験結果	114
表 4.4	一般道夕方逆光シーンの実験結果	116

第1章 序論

1.1 背景

日本の自動車保有台数が約 8200 万台^[1-1]にまで達する現在、自動車の交通事故は依然として身近なリスクである。図 1.1 に示す、警察庁交通局が発表の平成 30 年までの交通事故発生状況の推移によると^[1-1]、平成 30 年においても交通事故の発生件数は年間約 43 万件であり、死傷者数は年間約 52 万人（死者数 3,532 人、負傷者数 525,846 人）である。依然として多い交通事故であるが、図 1.1 からは、直近の 12 年間における交通事故発生件数及び死傷者数が減少傾向にあることも読み取れる。死者数減少の一要因は、シートベルト着用率の向上である。事実、死者数の推移を見ると、一般道においてシートベルト着用が義務化された平成 4 年を境に、減少が確認できる。そして、交通事故発生件数及び負傷者までを含めた死傷者数の減少に対する要因としては、ITS（Intelligent Transport Systems：高度道路交通システム）^[1-3]の 9 つの開発分野の 1 つである、「安全運転の支援」における研究成果が貢献している。

ITS とは、最先端の情報通信技術を用いて人と道路と車両とを一体のシステムとして構築することにより、道路交通が抱える事故、渋滞や環境対策など、様々な課題の解決を目的とする高度な交通システムのことである。ITS の安全運転支援の分野では、交通事故の発生防止や被害軽減を目的に、ADAS（Advanced Driver Assistance Systems：先進運転支援システム）、ADAS を搭載した自動車を指す ASV（Advance Safety Vehicle：先進安全自動車）の研究・開発が進められている。

図 1.2 に示す平成 30 年において発生した交通事故の事故類型別割合より、交通事故全体の約 86%が車両相互による事故であり、そのなかでも追突事故が最も多く約 40%を占める。また、図 1.3 に示す事故要因別割合より、交通事故の約 95%はドライバの法令違反であり、なかでも脇見運転などの安全運転義務違反が 75%と最も多い。これらのことから交通事故は、ドライバのヒューマンエラーが原因で発生する追突事故が最も多いと考えられる。



図 1.1 交通事故発生状況の推移

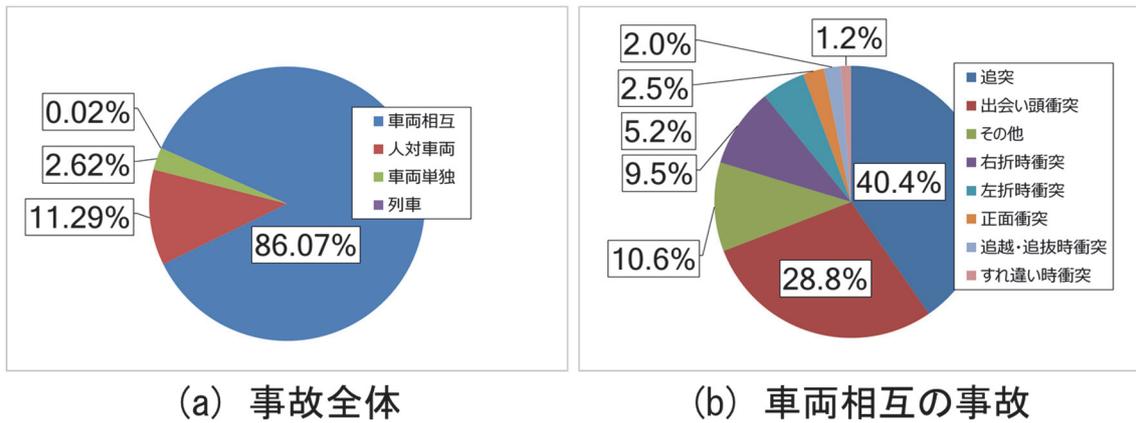


図 1.2 平成 30 年における交通事故の事故類型別割合

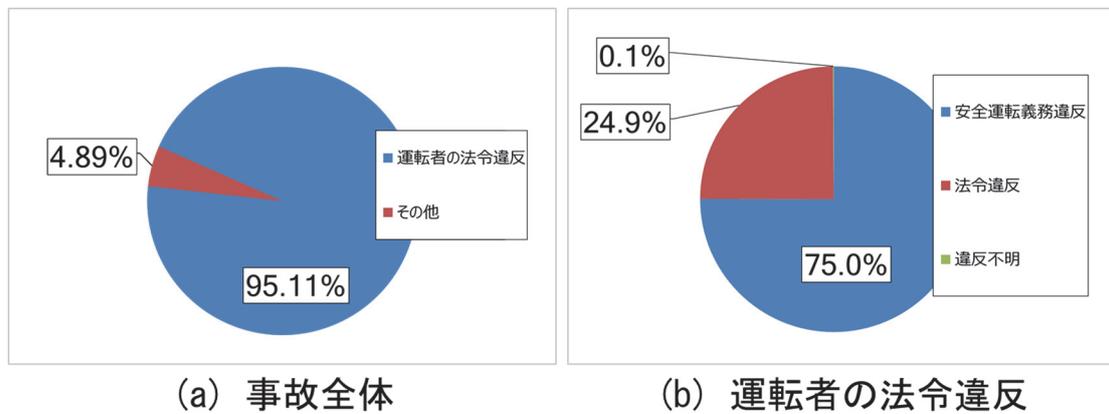


図 1.3 平成 30 年における交通事故の事故要因別割合

こういった追突事故の防止・低減を実現する ADAS には AEBS (Advanced Emergency Braking System : 衝突被害軽減ブレーキ) があり、実現のためには、車両前方の交通環境情報を取得可能なセンサを利用した先行車両検出が必要となる。先行車両検出の方式は、入力系によりレーダ系とマシンビジョン系に大別できる^[1-4]。レーザレーダやミリ波レーダを利用するレーダ系の方式は、様々な天候に対応しやすく、距離計測の精度も良いというメリットがある反面、道路の区画線 (道路白線) 抽出や物体認識が行えない、広い視野角が得られないといったデメリットがある。カメラを利用するマシンビジョン系の方式は、レーダ系に比べて得られる情報が多く、物体認識が可能というメリットがある反面、精度は大雨や逆光などの周囲の環境に左右されやすいといったデメリットがある。

上述のように、AEBS を代表とする ADAS は、様々なセンサを用いて実現されるが、そのなかでも多くの情報量を持つカメラを利用した画像処理は、今後も ADAS のなかで有力な手段になる。画像処理による先行車両検出では、ステレオカメラを利用した手法^{[1-5][1-6]} (複眼視) と単眼カメラを利用した手法^{[1-7][1-8]} (単眼視) がそれぞれ提案されている。ステレオカメラを利用した手法は、2つのカメラから取得する画像同士を対応付けるステレオマッチングにより画像上の対象物体までの距離推定が可能であり、立体物としての認識が行える利点がある。欠点としては、カメラの校正が煩雑であることや、画像の対応付けを精度良く行うために処理時間が増加する点が挙げられる。一方、単眼カメラを利用した手法は、設置が容易であり追加設置が可能であることや、画像の対応付け等が不要なため計算量を少なく抑えられるといった利点がある。欠点としては、距離推定を行うためには抽出対象に何らかの拘束条件を設定しなければならない点が挙げられる。実用化されている画像処理を利用した先行車両検出システムとしては、先行車両の形状や位置を把握することに優れている単眼カメラと距離計測に優れているレーダを併用して、車両認識と距離計測を別々のデバイスで行うもの^[1-9]や、複眼視を用いてカメラのみで車両認識と距離計測を行うもの^[1-10]などがある。

現在は、国土交通省の ASV 推進計画第 6 期 (2016 年~2020 年) に相当し、表 1.1 に示す運転自動化技術レベル^{[1-11][1-12]}のレベル 1, 2 相当、すなわち運転の主体が人 (ドライバ) となる機能を搭載した「運転支援車」の普及促進をはかっている段階にある。国際連合欧州経済委員会 (UNECE) は、2019 年 2 月に日本を含む世界およそ 40 か国が AEBS の新車への

搭載を義務付ける規制案に同意したことを発表し^[1-13]、2019年6月にはAEBSの協定規則（UN-R152）^[1-14]が国連自動車基準調和フォーラム（WP29）において成立された。これを受け日本は、2020年1月31日に国内基準を改正・公布し、2021年11月以降の国内新車にAEBSの搭載を義務付けることを世界に先駆け決定した^[1-15]。

表 1.1 運転自動化レベルの概要
 (SAE J3016:SEP2016^[1-11], JASO TP18004:2018^[1-12])

レベル	名称	動的運転タスク		動的運転タスクの作動継続が困難な場合への対応	限定領域
		持続的な縦・横の車両運動制御	対象物・事象の検知及び応答		
運転者が一部又は全ての動的運転タスクを実行					
0	運転自動化なし	運転者	運転者	運転者	適用外
1	運転支援	運転者とシステム	運転者	運転者	限定的
2	部分運転自動化	システム	運転者	運転者	限定的
システムが（作動時は）全ての動的運転タスクを実行					
3	条件付運転自動化	システム	システム	応答準備ができていない利用者（基本的に運転者）	限定的
4	高度運転自動化	システム	システム	システム	限定的
5	完全運転自動化	システム	システム	システム	限定なし

しかし、現行車には非搭載車両も多く、後付けで搭載するタイプのAEBSや前方車両衝突警報システムにはコストなどの点で依然課題が残っている現状がある。また近年、防犯の目的などで設置の容易なドライブレコーダが注目され、一般車両においても需要が増加しており、なかにはADASの機能を有する製品も販売され始めている。以上のことから、車載単眼カメラを利用することで安価に導入でき、現行車に追加設置可能なADASへの需要がある。

1.2 関連研究と本論文の目的

本論文では、単眼カメラを利用した手法の利点に着目し、車載単眼カメラとコンピュータを利用した画像処理による先行車両検出システムとすることで、自動車への追加設置が容易なドライブレコーダなどの車載単眼カメラを利用した運転自動化技術レベル1、2相当のADASへ応用可能な技術開発を目指す。また本論文では、単眼視による車間距離推定を可能にするために、先行車両の車両特徴（車両であることを示す画像特徴）としてこれまで注目されることの少なかった、車両下にできる路面上の影（以降、車両下影と呼ぶ）に着目する。車両下影の特徴を以下に示す。

- ・ 低輝度で、輝度のばらつきも少ない
- ・ 車幅程度の大きさを持つ
- ・ 車両下に必ず存在する
- ・ 路面上に拘束される

車両下影は周囲の環境に依らず低輝度で、ばらつきも少ないという特徴を持ち、照明変動により車両の影は大きさや形が変化するが、基本的には車両下影が一番暗く、そこから離れるほど明るくなるため、局所的に暗い領域を抽出する方法などで比較的容易に車両下影の候補を抽出できる。また、車幅程度の大きさを持つことから遠方においても抽出が可能といった利点に加え、車両下かつ路面上に必ず存在するという拘束条件から、単眼視による距離推定が可能となる利点もある。

以降では、車載単眼カメラを用いた車間距離推定の関連研究、車載単眼カメラを用いた先行車両検出及び先行車両追跡の関連研究について述べ、それらを踏まえた本論文の目的について述べる。

1.2.1 車載単眼カメラを用いた車間距離推定の関連研究

本項では、車載単眼カメラを用いた車間距離推定の関連研究について述べる。単眼カメラの場合、ステレオマッチングを利用できないため、何らかの特徴をもとに透視投影により距離を推定する必要がある。この特徴として画像内の車幅^[1-16]や画像内の車両下端の位置^[1-17]が考えられる。なお、画像上における車両のスケール変化率から衝突時間（TTC：Time to Collision）を推定する手法は存在する^[1-18]が、車間距離を推定するものではない。

車幅を用いる場合、あらかじめ設定する平均車幅と検出した車両の幅を比較して距離を推定するが、車幅は通常 1.5m~2m, 特殊車両等を含めると 3m 程度までの幅があるため、検出した車両が平均的な車幅から逸脱する場合に大きな誤差につながる。これに対し Stein ら^[1-17]は、車両背面の特徴を学習した識別器などにより画像から検出した車両矩形の下端が路面と接地する点、すなわちタイヤであると仮定し、逆透視変換により車間距離を推定する手法を提案しており、車幅を用いた手法よりも安定して距離推定が可能な点を主張している。図 1.4 に、タイヤを用いた単眼車載カメラによる距離推定の概要を示す。

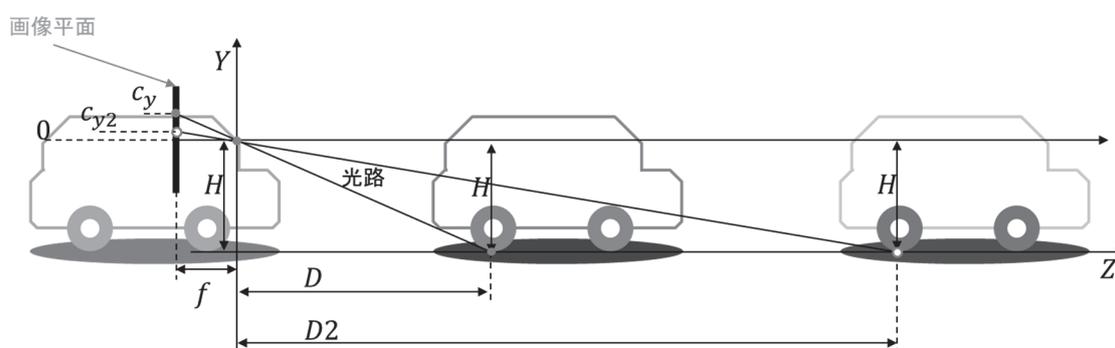


図 1.4 タイヤを用いた車間距離推定の概要図

図 1.4 のような平坦な路面と光軸が平行になるようにカメラを設置したピンホールカメラモデルを想定したとき、水平線は画像平面の中央に現れる。このモデルにおいてカメラ前方の距離 D [m] に位置する車両の下端は水平線から高さ c_y [pixel] で画像に投影される。カメラの設置高さを H [m], ピクセルに換算した焦点距離を f [pixel] とすると、三角形の相似性から車両下影までの距離 D [m] を式(1.1)により求めることができる。

$$D = \frac{fH}{c_y} \quad (1.1)$$

図 1.4 に例示するように、距離 D [m] よりも遠方の距離 $D2$ [m] に位置する車両の下端は、水平線からの高さ c_y [pixel] よりも小さい c_{y2} [pixel] で画像に投影されるため、式(1.1)により画像内の座標 [pixel] を用いて適切な関係を反映した距離 [m] を算出できる。また、距離の推定誤差 D_{err} [m] は、画像内での車両下端の y 座標誤り画素 p_{err} [pixel] に依り、 p_{err} [pixel] 誤ったときの推定距離を D_p [m] とすると式(1.2)で算出できる^[1-17]。

$$D_{\text{err}} = D_p - D = \frac{fH}{c_y + p_{\text{err}}} - D = \frac{fH}{\frac{fH}{D} + p_{\text{err}}} - D = \frac{D^2 p_{\text{err}}}{fH + D p_{\text{err}}} \quad (1.2)$$

一般に $fH \gg D p_{\text{err}}$ が成り立つため、式(1.2)による距離の推定誤差 D_{err} は対象までの距離 D の二次関数とみなせ、 D が大きくなるほど p_{err} の影響が顕著に表れるため、距離推定のためには厳密に車両が路面に接地する座標の推定が必要となる。従来の単眼車載カメラによる距離推定では Stein らのように検出矩形の下端がタイヤであり、路面接地しているとみなす手法が多いが、一般的な物体検出では画像内のおおよそを対象物が占めるような学習サンプルを用いて識別器の構築を行うため、検出矩形の下端が常に路面接地とは限らない問題がある。また、車種によってはタイヤが見えないこともあるため、タイヤを特徴としても検出できないおそれもある。

1.2.2 車載単眼カメラを用いた先行車両検出及び追跡の関連研究

本項では、車載単眼カメラを用いた先行車両検出及び追跡に関するサーベイ論文^{[1-19]-[1-21]}を基に本論文の関連研究に目を向ける。

先行車両検出は大きく、動きに基づく手法と外観に基づく手法に分けられる。動きに基づく手法にはオプティカルフローに基づき長時間にわたって自車両と並走する関心点として車両を検出するもの^[1-22]などがあるが、画像全体の変位を計算する必要があるため計算コストが高いことに加え、特徴点を基準とするため単眼視での距離推定が困難であり、また車両として認識するためには外観に基づく手法と統合する必要がある。以上の理由から複眼視において有力であるが、単眼視においては外観に基づく手法ほど一般的でない。

外観に基づく手法は一般に仮説生成 (HG: Hypothesis Generation) と仮説検証 (HV: Hypothesis Verification) のステップに分けられるが、多少の重複もあり厳密には区別されないことも多い。仮説生成は、画像内から高速に車両の候補位置を仮説として抽出するステップである。仮説検証は、抽出された車両候補領域、すなわち仮説が車両か否かを検証し、最終的な車両検出結果を得るステップである。仮説生成に用いる特徴として一般的なものは、知識ベースで設計される色、左右対称性、エッジである。先行車両は様々な色を持つため色情報のみで仮説を生成する研究はほとんどないが、ブレーキランプの検出^[1-23]などにおいては有力な特徴である。左右対称性の情報は 1990 年代初頭に車両の特徴として用いられていた^[1-24]が雑音に敏感であるため、近年はエッジなどの他の特徴に組み込まれて利用される。

車両の背面にはリアウィンドウやバンパーといった多くの水平及び垂直エッジが含まれるため、エッジ情報は有力な特徴として用いられている。Betke ら^[1-16]は画像の水平エッジと垂直エッジを評価して長方形の物体を探索しており、画像全体から顕著なエッジを探索することで仮説生成を行い、顕著なエッジを持つ領域に対して詳細にエッジ特徴を解析することで仮説検証までを行っている。画像から検出した車幅[pixel]及び車高[pixel]と、予め設定する一般的な車幅[m]及び車高[m]を対応づけることで距離推定も行っているが、設定する車幅や車高が重要なパラメータとなり、またエッジの集合のみで車幅や車高を推定するため信頼性に欠く。Sun ら^[1-19]及び Yangt ら^[1-21]のサーベイ論文では本論文で仮説生成の特徴として用いる影の利用に言及しているが、どちらも車両下影の例としては共通で Tzomakas ら^[1-25]の手法を挙げるにとどまり、Yangt らは車両検出の性能改善を目的として除去するための特徴^[1-26]としてまとめている。

さらに、単純な色やエッジよりも頑健な特徴として、Haar-like 特徴量^[1-27]や HOG (Histogram of Oriented Gradients) 特徴量^[1-28]などの画像局所特徴量の利用検討が主に仮説検証のステップにおいて進められてきた。Khairdoost ら^[1-29]は、Tzomakas ら^[1-25]の手法より抽出した車両下影にテクスチャと対称性の特徴を加えて車両領域までを含んで仮説生成する手法と、HOG 特徴量を拡張した PHOG (Pyramid Histograms of Oriented Gradients) 特徴量をそれぞれ提案し、PHOG 特徴量を基に仮説検証する手法を構築している。しかし、仮説生成と仮説検証を統合した先行車両検出の枠組みとして構築しておらず、精度も PHOG 特徴量に基づいた検出のみ検証するにとどまっている。また、処理時間に関する記述はないが仮説生成ステップにおける計算の効率化を課題として挙げており、リアルタイム処理への課題が残っている。

また、先行車両追跡には大きく、テンプレートマッチングなどの領域に基づく手法^[1-30]やオプティカルフローなどの特徴点に基づく手法^[1-31]がある。Lim ら^[1-30]は、追跡の前段階としての車両検出において車両下影に着目した仮説生成を行うが、追跡には輝度値に基づいた車両領域テンプレートを更新して用いており、影の特徴は用いていない。よって、本論文のように車両下影を抽出対象とする研究は少なく、追跡対象にまでする取り組みはほとんど見受けられない。

1.2.3 本論文の目的

本論文は、路面上に拘束される車両下影を効果的に用いることによる単眼視での距離推定までを見据えた、リアルタイムで動作する先行車両検出及び追跡の実現を目的とする。

Stein ら^[1-17]と同様の考えのもと、車両と路面との接地点を用いた逆透視変換により距離推定を行うが、本論文では車両と路面との接地を表す特徴として車両下影に着目する。図 1.5 に車両下影を用いた車間距離推定の概要を示す。

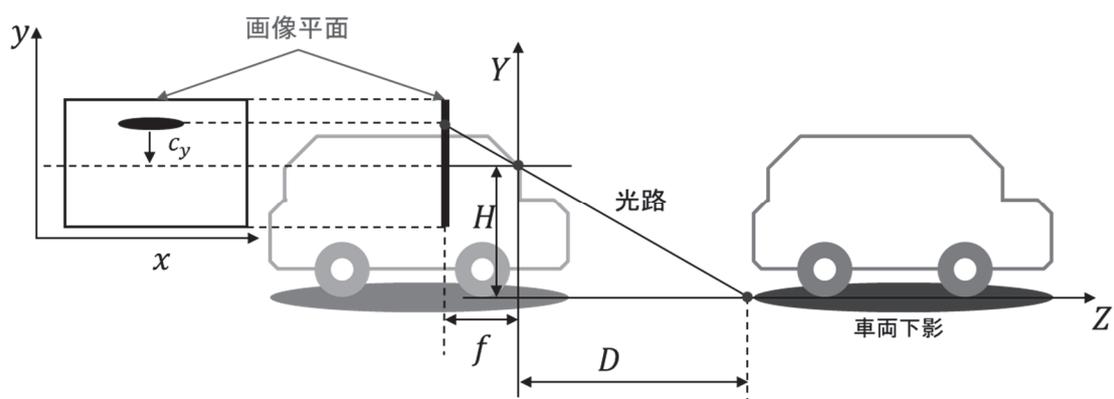


図 1.5 車両下影を用いた車間距離推定の概要図

本論文では、仮説生成における計算効率化の一環及び距離推定のための消失点抽出としての白線（道路区画線）抽出、車両下影を用いた仮説生成と画像局特徴量を用いた仮説検証の統合による先行車両検出、車両下影の特徴と領域に基づいた特徴の統合による車両下影追跡についてそれぞれ新しい手法を提案し、有効性を検証した。

1.3 本論文の構成

本論文は、白線エッジ特徴を考慮したエッジ重畳による道路白線抽出（第2章）、車両下影抽出と車両識別による影に着目した先行車両検出（第3章）、Particle Filterによる影らしさと車両らしさを考慮した車両下影追跡（第4章）、及び結論（第5章）から構成している。

図 1.6 に、本論文での提案をまとめ構築する先行車両検出システムの流れを示す。

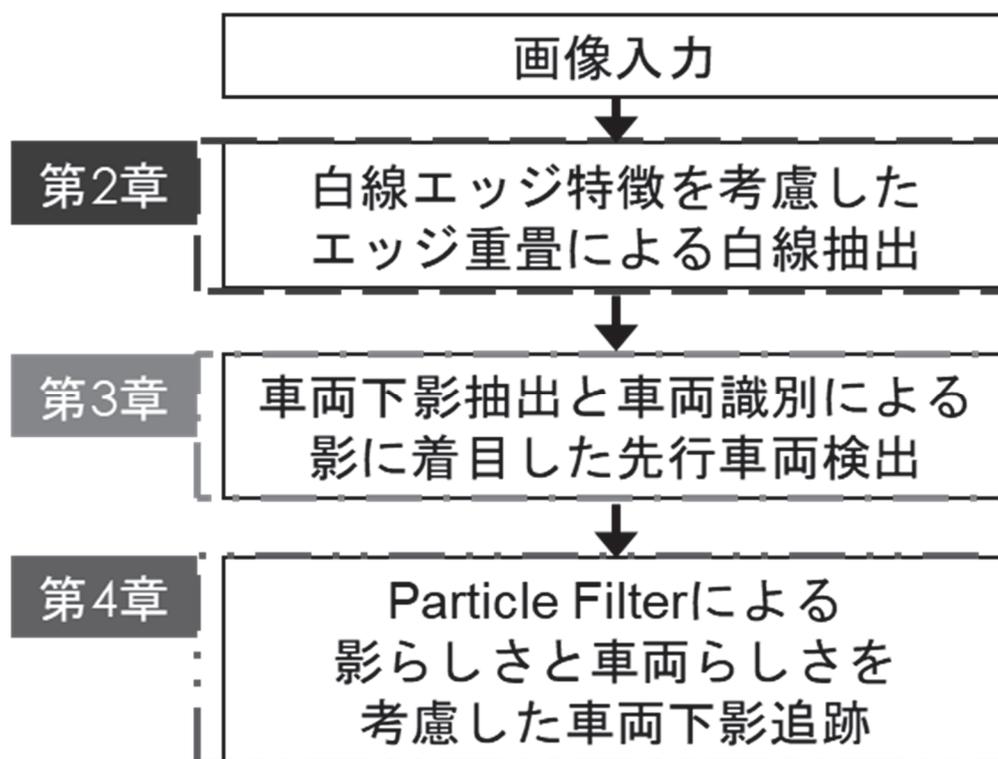


図 1.6 先行車両検出システムの流れ

第2章で提案する手法により自車両が走行するレーンの白線を抽出する。抽出した白線内に処理領域を限定し、第3章で提案する手法により車両下影に基づいて先行車両を検出する。検出した先行車両の車両下影位置と車両スケールを初期値として、第4章で提案する手法により先行車両下影を追跡する。

各章の概要を以下に示す。

第2章 白線エッジ特徴を考慮したエッジ重畳による道路白線抽出

白線（道路区画線）抽出の関連研究について述べた後、本論文で提案する、白線エッジの特徴を考慮したエッジ重畳による白線抽出について述べる。従来の白線抽出^{[1-32]-[1-35]}は、エッジ抽出により白線の候補点を抽出し、得られた候補点から直線を推定するものなどが多いが、破線状の白線など、候補点が少ない場合に、少ない候補点からでも抽出できるようにする取り組みが基本であった。本論文では、エッジ重畳により候補点を補完することで、単純な処理により破線状の白線も抽出できる手法を構築した。なお、白線抽出は、本論文で提案する影に着目した先行車両抽出処理の処理領域を限定するために用いる。

第3章 車両下影に着目した車両識別による先行車両検出

本論文と同様に車両下影に着目した車両検出の関連研究について述べた後、本論文で提案する、車両下影に着目した車両識別による先行車両検出について述べる。従来の影に着目した先行車両検出手法^{[1-25][1-36]-[1-38]}は、エッジで囲まれる走行可能領域内の輝度値が正規分布に従うという仮定のもとに影を抽出する手法に基づくものが多く、その発展としてエッジ情報を加えて利用するものもあるが、事前に設定するエッジの閾値を必要とする。さらに車両下影抽出と車両背面の特徴を学習した識別器などによる車両抽出を統合して車両検出を行う検討はなく、車両下影の抽出をもって車両検出とするのは信頼性に欠ける点が問題としてあった。本論文では、輝度値が低いという影の特徴に基づき、統計量と局所的な特徴を用いて車両下影候補を抽出し、かつ車両下影の上部領域に対して機械学習により構築する車両識別器を適用して、車両の有無を識別する2段階を踏むことで、車両としての信頼性を担保する先行車両検出手法を提案した。

第4章 Particle Filter による影らしさと車両らしさを考慮した車両下影追跡

一般的な物体追跡や、本論文と同様に車両下影を利用した車両追跡の関連研究について述べた後、本論文で提案する影らしさと車両らしさを考慮した先行車両追跡について述べる。画像中の物体追跡においては、追跡対象を領域に基づいて処理し、検出しながら追跡する **Tracking-by-detection** と呼ばれる手法が主流である。本論文の追跡対象である車両下影は、車両領域の一部に含まれるため、領域に基づいた車両追跡により影も合わせて追跡できるように思われるが、領域に基づいた追跡は通常物体領域の中心を精度良く追跡するため、一

一般的な追跡手法では物体領域に対して端に位置する影の特徴は重要視されない問題があった。加えて車両下影は、車両背面のように形状を表す特徴が良く現れる領域に対して現れる特徴も少なく背景に紛れやすいため、車両下影を領域中心においた追跡では車両を領域中心においた追跡ほどの性能が発揮できない問題もあった。本論文では、追跡対象としての尤もらしさ、すなわち尤度を基にモンテカルロ法により物体追跡を行う Particle Filter を利用して、その尤度を表す特徴に輝度及びテクスチャによる影らしさと物体追跡手法の一つ KCF^[1-39]を応用する車両らしさを組み合わせ、高精度に車両下影を追跡する手法を構築した。

第 5 章 結論

本論文の成果についてまとめた後、今後取り組むべき課題について述べる。

文 献

- [1-1] 一般財団法人自動車検査登録情報協会ホームページ
<http://www.airia.or.jp/number/index.html> (2020-02)
- [1-2] 警察庁ホームページ：『平成 30 年における交通事故の発生状況』,
<https://www.npa.go.jp/publications/statistics/koutsuu/toukeihyo.html> (2020-02)
- [1-3] 国土交通省道路局「ITS（高度道路交通システム）の推進」,
<http://www.mlit.go.jp/road/ITS/j-html/> (2020-02)
- [1-4] 二宮芳樹：「ITS における自動車の高機能化－走行環境認識技術」, 電子情報通信学会技術研究報告. CST, Vol.99, No.98, pp.33-39 (1999)
- [1-5] 実吉敬二・埴 圭二・十川能之・荒井一真：「ステレオ画像を用いた運転支援のための前方状況認識システム」, 電子情報通信学会技術研究報告. PRMU, Vol.97, No.41, pp.39-46 (1997)
- [1-6] 網島宣浩・中島真人：「投影 c v 視差画像を用いた前方車両の検出」, 電気学会論文誌 C, Vol.120, No.3, pp.337-344 (2000)
- [1-7] 山田憲一・伊東敏夫：「エッジ画像の濃度投影による車両の一補足手法」, 電気学会論文誌 E, Vol.118, No.6, pp. 327-332 (1998)

- [1-8] 渡邊信太郎・関真規人・鹿毛裕史・鷺見和彦：「コンテキストを用いた動画像からの対象認識の高精度化」, 電子情報通信学会論文誌 D, Vol.J92-D, No.4, pp.521-530 (2009)
- [1-9] ボルボ カーズ ジャパン ホームページ,
<http://www.volvocars.com/jp/Pages/default.aspx> (2020-02)
- [1-10] SUBARU アイサイト総合サイト ホームページ,
<https://www.subaru.jp/safety/eyesight/> (2020-02)
- [1-11] SAE International: “Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles“, J3016:SEP2016, SURFACE VEHICLE RECOMMENDED PRACTICE (2016)
- [1-12] 公益社団法人 自動車技術会：「自動車用運転自動化システムのレベル分類及び定義」, JASO テクニカルペーパー, TP-18004:2018 (2018)
- [1-13] UNECE: “Press Release - UN Regulation on Advanced Emergency Braking Systems for cars to significantly reduce crashes”, <https://www.unece.org/?id=51189> (2020-04)
- [1-14] UN Regulation No.152: “Uniform provisions concerning the approval of motor vehicles with regard to the Advanced Emergency Braking System (AEBS) for M1 and N1 vehicles” (2020)
- [1-15] 国土交通省：報道・広報「乗用車等の衝突被害軽減ブレーキに関する国際基準を導入し、新車を対象とした義務付けを行います。～道路運送車両の保安基準の細目を定める告示等の一部改正について～」,
https://www.mlit.go.jp/report/press/jidosha08_hh_003618.html (2020-04)
- [1-16] M. Betke, E. Haritaglu, and L. Davis: “Real-Time Multiple Vehicle Detection and Tracking from a Moving Vehicle”, Journal of Machine Vision and Applications, Vol.12, No.2, pp.69-83 (2000)
- [1-17] G. P. Stein, O. Mano, and A. Shashua: “Vision-based ACC with a Single Camera: Bounds on Range and Range Rate Accuracy”, Proc. on IEEE Intelligent Vehicles Symposium(IV2003), pp.120-125 (2003)
- [1-18] E. Dagan, O. Mano, G. P. Stein, and A. Shashua: “Forward Collision Warning with a Single Camera”, Proc. on IEEE Intelligent Vehicles Symposium(IV2004), pp.37-42 (2004)

- [1-19] Z. Sun, G. Bebis and R. Miller: "On-Road Vehicle Detection: A Review", IEEE Trans. on Pattern Analysis and Machine Intelligence(PAMI), Vol.28, No.5, pp.694-710 (2006-05)
- [1-20] S. Sivaraman and M. M. Trivedi: "Looking at Vehicles on the Road: A Survey of Vision-Based Vehicle Detection, Tracking, and Behavior Analysis", IEEE Trans. on Intelligent Transportation Systems(ITS), Vol.14, No.4, pp.1773-1795 (2013-12)
- [1-21] Z. Yangt and L.S.C. Pun-Cheng: "Vehicle detection in intelligent transportation systems and its applications under varying environments: A review", Journal of Image and Vision Computing, Vol.69, pp.143-154 (2018)
- [1-22] A. Jazayeri, H. Cai, J. Y. Zheng, and M. Tuceryan: "Vehicle Detection and Tracking in Car Video Based on Motion Model", IEEE Trans. Intelligent Transportation Systems(ITS), Vol.12, No.2, pp.583-595 (2011-06)
- [1-23] D.Y. Chen, Y.H. Lin, and Y.J. Peng: "Nighttime Brake-light Detection by Nakagami Imaging", IEEE Trans. on Intelligent Transport Systems, Vol.13, No.4, pp.1627-1637 (2012-12)
- [1-24] A. Kuehnl: "Symmetry-based recognition of vehicle rears", Journal of Pattern Recognition Letters, Vol.12, Issue 4, pp.249-258 (1991)
- [1-25] C. Tzomakas and W. von Seelen: "Vehicle Detection in Traffic Scene Using Shadows", Technical Report 98-06, Institut für Neuroinformatik, Ruhr-Universität, Bochum, Germany (1998)
- [1-26] H. Asaidi, A. Aarab, and M. Bellouki: "Shadow elimination and vehicles classification approaches in traffic video surveillance context", Journal of Visual Languages and Computing, Vol. 25, Issue 4, pp.333-345 (2014-08)
- [1-27] P. Viola and M. Jones: "Rapid object detection using a boosted cascade of simple features", in Proc. IEEE Conf. on Computer Vision and Pattern Recognition(CVPR), Vol. 1, pp. 511-518 (2001)
- [1-28] N. Dalal and B. Triggs: "Histograms of Oriented Gradients for Human Detection", in Proc. IEEE Conf. on Computer Vision and Pattern Recognition(CVPR), Vol.1, pp. 886-893 (2005)

- [1-29] N. Khairdoost, S. A. Monadjemi, and K. Jamshidi: “Front and Rear Vehicle Detection Using Hypothesis Generation and Verification”, *Signal & Image Processing : An International Journal (SIPIJ)*, Vol.4, No.4, pp.31-50 (2013-08)
- [1-30] K. H. Lim, L.-M. Ang, K. P. Seng, and S. W. Chin: “Lane-Vehicle Detection and Tracking”, *Proc. of International MultiConference on Engineers and Computer Scientists(IMECS)*, Vol.II (2009)
- [1-31] Y. Zhu, D. Comaniciu, V. Ramesh, M. Pellkofer, and T. Koehler: “An Integrated Framework of Vision-based Vehicle Detection with Knowledge Fusion”, in *Proc. IEEE Intelligent Vehicles Symposium(IV)*, pp.194-204 (2005)
- [1-32] 堀江宏仁・小澤慎治:「連続道路画像を用いた車両前方監視」, 電気学会論文誌C, Vol.117, No.5, pp.648-657 (1997)
- [1-33] 網島宣浩・佐藤泰則・中澤和夫・中島真人:「回転型フィルタを用いた車両前方走行画像からの白線認識」, 電子情報通信学会論文誌D-II, Vol.J81-D-II, No.6, pp.1470-1473 (1998)
- [1-34] 山口直人・田森信行・塩見彰睦:「適応エッジ保存平滑化を用いた白線検出手法」, 電子情報通信学会論文誌D-II, Vol.J88-D-II, No.8, pp.1421-1431 (2005)
- [1-35] 農宋千典・小澤慎治:「高速道路走行画像からの消失点推定に基づく実時間白線検出」, 電気学会論文誌C, Vol. 113, No.2, pp.139-148 (1993)
- [1-36] S.-S. Huang, C.-J. Chen, P.-Y. Hsiao, L.-C. Fu: “On-Board Vision System for Lane Recognition and Front-Vehicle Detection to Enhance Driver’ s Awareness”, in *Proc. IEEE International Conference on Robotics and Automation(ICRA)*, Vol.3, pp.2456-2461 (2004)
- [1-37] Z. Liu, Z. Sun, H. He: “On-road Vehicle Detection Fusing Radar and Vision”, in *Proc. IEEE International Conference on Vehicular Electronics and Safety (ICVES)*, pp.150-154 (2011)
- [1-38] Nur Shazwani A., M. M. Ibrahim, N. M. Ali, Nur Fatin Izzati Y.: “Vehicle Detection Based on Underneath Vehicle Shadow Using Edge Features”, in *Proc. IEEE International Conference on Computer Science Education (ICCSE)*, pp. 407-412 (2016)
- [1-39] J. F. Henriques, R. Caseiro, P. Martins, and J. Batista: “High-Speed Tracking with Kernelized Correlation Filter”, *IEEE Trans. on PAMI*, Vol. 37, No. 3, pp. 583-596 (2015)

第2章 白線エッジ特徴を考慮したエッジ重畳による道路白線抽出

2.1 白線抽出の関連研究と本研究の位置づけ

本研究では、車内に設置する車載単眼カメラを用いて取得する車両前方画像に対して画像処理を行うことにより車両下影を抽出し、それを基に先行車両検出を実現する。本研究において道路白線（道路区画線）の抽出は、車両下影抽出を高速化、高精度化するために用いており、白線抽出の結果に基づいて車両下影抽出のための処理領域を限定する。

道路白線は、一般に路面上で目立つように描かれるため路面との輝度差が大きいという特徴がある。現在、車両前方画像から白線を抽出する手法として、路面との輝度差を利用して白線候補点を抽出し、白線候補点を結び直線として白線を抽出するもの^{[2-1][2-4]}や、白線を模した直線のモデルに適合する白線候補点を見つけるもの^{[2-5][2-6]}など数多く提案されている。

白線候補点の抽出手法には、輝度値を用いた単純な 2 値化よりも照明変動の影響を受けにくい、微分フィルタを用いたエッジ抽出によるものが多い^{[2-1][2-3][2-7][2-8]}。微分フィルタを用いた手法では、白線エッジ以外の道路標示や建物などの影によるエッジをいかに抑制するかが問題となる。まず、白線は特に水平方向の輝度変化が大きいことに着目し、垂直エッジのみを利用する手法^{[2-1][2-2][2-7]}がある。これらの手法では、道路を覆う建物の影など雑音となる水平エッジを抑制できるが、道路標示も一般に垂直方向のエッジが強いため白線と同様に抽出される問題がある。次に、画像上で左右の白線は消失点に向かうことから経験的にそれぞれ斜め方向のエッジとなるため、抽出するエッジを斜め方向のみに限定する手法^[2-8]がある。垂直エッジのみに限定するよりも道路標示などによる雑音の影響を抑制できるが、適用可能な道路構造を狭め、カーブシーンなどへの対応が難しくなる問題がある。さらに、微分フィルタを用いたエッジ抽出では細かな撮像雑音もエッジとして現れることから、エッジ抽出の前に平滑化を行いこの影響を抑制する手法^{[2-2][2-3]}がある。適応エッジ保存平滑化

を用いた手法^[2-2]では、白線エッジを保持したまま雑音抑制が可能となるが、繰り返し計算が必要になるほか、建物の影など白線に関係のないエッジも保存してしまう。Canny 法によるエッジ抽出を用いた手法^[2-3]では、連続性のあるエッジ点のみを抽出できるが、Sobel フィルタなどの手法と比較すると計算コストが高いことや、エッジが細線化されることを考慮して用いる必要があるほか、エッジ方向を利用するためには別の微分処理などが必要となる。文献[2-3]ではまた、エッジ抽出を事前に設定した領域内に行っている点も課題である。さらに路面上において白線の特徴的なパターンを利用して白線候補点を抽出する手法がある^[2-5]。白線は両端にエッジを持ち、水平方向の微分フィルタを適用すると、白線の左側に正、右側に負のエッジが現れるため、正負のエッジピークを利用することで、影などの雑音を抑制することができるが、道路標示も同様に抽出される可能性がある。

白線候補点から直線として白線を抽出する手法には、破線状の白線などからも直線を抽出可能な Hough 変換が多く用いられている^{[2-1]-[2-4]}。堀江ら^[2-1]は、Hough 空間における投票分布の時間的な重なりを考慮することで、各フレームにおける雑音の影響を軽減し、白線抽出の頑健性を高めている。安達ら^[2-3]は、Hough 空間への投票時に、エッジ点のばらつきを重みとして考慮することで、エッジ点がばらつくような雑音に対する白線抽出の頑健性を高めている。一方、白線候補点から白線を抽出するのではなく、消失点を基にそれを構成する白線候補点群として直線を抽出する手法^{[2-7][2-8]}がある。綱島ら^[2-7]は、白線が消失点から放射状に広がる直線上に存在するという仮定を用いて、回転フィルタを適用して領域内のエッジ点を数え、エッジ点の多い領域に対する最小二乗法により白線を抽出する手法を提案している。消失点を基に直線を抽出することで白線の存在し得る方向に抽出を限定できるが、道路標示も同様に抽出し得る問題がある。関^[2-4]は、パーティクルフィルタの枠組みと Hough 変換を統合し、Hough 空間における投票度数を基にパーティクルの尤度を算出して消失点を追跡する手法を提案している。一つの消失点を追跡することで、その消失点を構成する直線を頑健に抽出することができるが、ほかの手法に比べて投票や尤度評価に計算コストが高くなる。また、白線候補点に対して、カーブなどの単純な直線以外の道路構造に対応した、白線モデルを適用する手法^{[2-5][2-6]}がある。大池^[2-5]は、モデル要素の移動を横方向のみに限定したストリングモデルを提案している。様々な道路形状に対応できるが、モデル収束までの反復計算が必要であり、破線やかすれなどの影響により収束が遅くなる。

本論文では一般的なフレームレートである 30fps の動画像の使用を想定しており、約 33ms 以内の処理をリアルタイム処理の目標としている。白線候補点から白線を抽出する処理は、先行車両検出の前処理であることを考慮すれば、低い計算コストであることが望ましく、複雑なモデルを適用する手法は適さない。さらに、一般道まで対象を広げた際に考えられる白線のかすれについては、かすれた白線候補点からも白線を抽出しようとする取り組みが多く、かすれた白線候補点そのものに対するものは見受けられない。また、一般道や雨天など、外乱の多い環境における論文レベルでの報告は少なく、建物の影や道路標示、雨滴やワイパーといった雑音となり得る要素を含んだ画像からの白線候補点抽出や白線抽出に関して、これらの要素を包括的に実験検討した報告例は著者の調査範囲においては見受けられない。

そこで、本論文では白線抽出の手法として、Hough 変換の投票さえも必要とせず、比較的簡単な処理で破線状の白線やペイントがかすれた白線への対応をはかるために、抽出した時系列のエッジ画像を重ね合わせるエッジ重畳に基づいた白線抽出を提案し、実用を見据え道路標示を含む一般道や雨天時といった環境において検討を行った^[2-9]。本論文で対象とするのは白線の描かれている道路であり、描かれていない道路については検討しない。これら研究対象外の環境や、実験で対象としきれない環境に関する考察等は 2.7 節で述べる。

2.2 白線エッジ特徴を考慮したエッジ重畳による道路白線抽出概要

本論文の抽出対象である先行車両の車両下影は、自車両走行レーン上に存在する。そのため、自車両走行レーンの白線を抽出し、以後に行う車両下影抽出の処理領域を自車両走行レーン内に限定する。これにより、対向車の影や歩道に存在する影などを車両下影に誤って抽出することを抑制する。また、処理領域限定による処理時間短縮の効果も期待できる。

2.1 節でも述べたとおり、白線は路面上に目立つように描かれているため、画像上で白線と路面の境界（エッジ）部分における輝度値の変化は急峻である。このことから、白線と路面のエッジの情報を利用して白線を抽出する。さらに破線状の白線やペイントがかすれた白線への対応をはかるために、抽出した時系列のエッジ画像を重ね合わせるエッジ重畳を行う。この際、効果的なエッジ重畳を実現するために、白線エッジ特徴を利用したエッジ抽出の手法もあわせて提案する。図 2.1 にエッジ重畳の概念を示す。

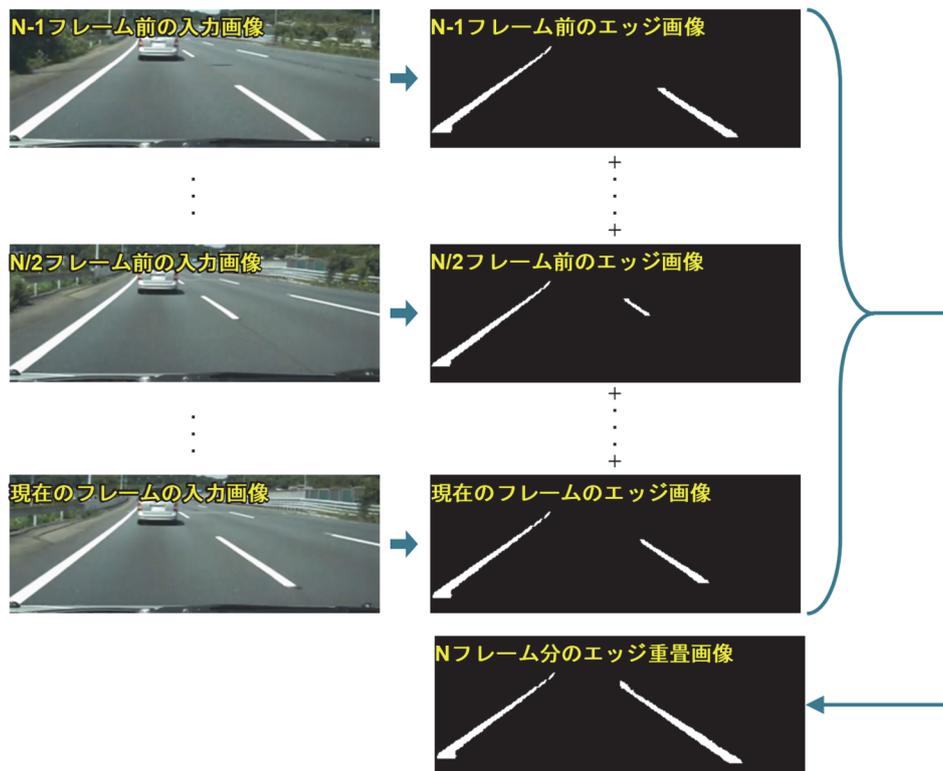


図 2.1 エッジ重畳の概念

図 2.2 に本論文で提案する白線抽出の流れを示す。

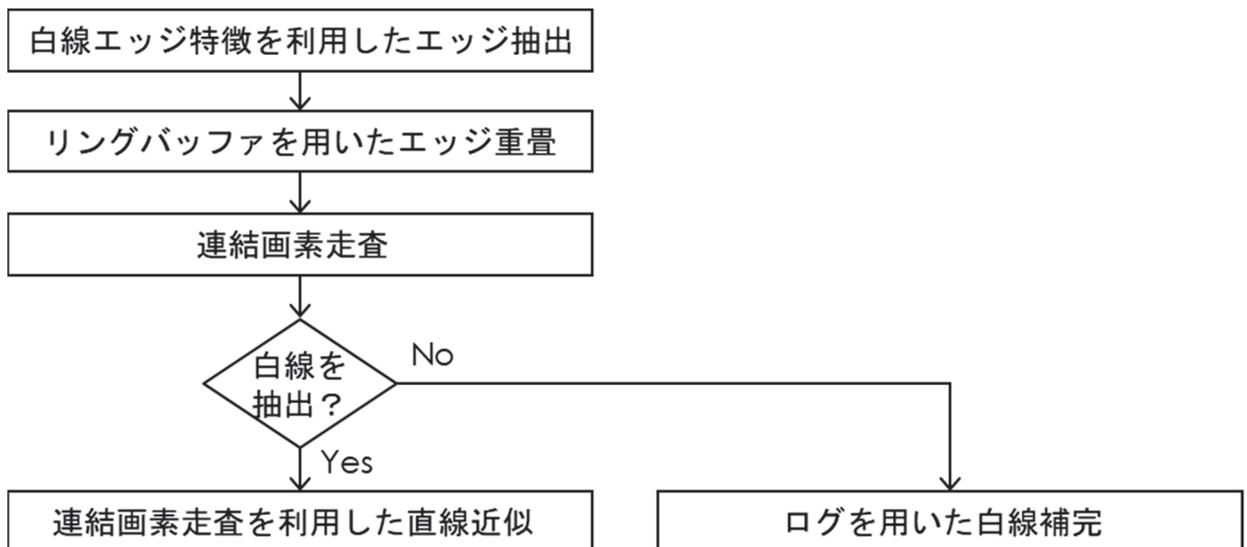


図 2.2 本論文で提案する白線抽出処理の流れ

まず、「白線エッジ特徴を利用したエッジ抽出」により道路標示などの雑音と白線とのエッジ方向の違いやエッジのピーク特徴を利用して雑音を抑制しつつ、白線候補点としてのエッジ点を抽出する。次に「リングバッファを用いたエッジ重畳」により破線やかすれに対

応できるように白線候補点を補完する。この際、エッジ画像を重畳するフレーム数を行方向で可変とし、雑音が比較的多く存在する画像中央付近で過剰に重畳されることを防ぐ。さらに極めて軽量の処理である「連結画素走査」により、連結する白線候補点の塊として白線を抽出する。ここで、現フレームのエッジ画像とエッジ重畳画像を段階的に走査する二段階構造とすることで、エッジの変化に鈍くなるエッジ重畳の欠点を軽減する。連結画素走査により白線候補点の塊が抽出できた場合、「連結画素走査を利用した直線近似」により抽出した候補点群の周辺情報を加味した近似直線を抽出し白線とする。白線候補点の塊が抽出できない場合、白線が存在しないとして「ログを用いた白線補完」により直近の白線抽出結果のログを用いて補完する。

2.3 白線エッジ特徴を利用したエッジ抽出

本節では、エッジ抽出の前処理として行うグレースケール変換について述べた後、エッジ抽出の概要を述べ、本論文で提案する白線エッジ特徴を利用したエッジ抽出について述べる。白線エッジ特徴を利用したエッジ抽出は、白線エッジの方向特徴を利用したエッジ抽出、白線エッジのピーク特徴を利用したエッジ選別、白線エッジの方向特徴を利用したエッジ補正の3つから構成する。

2.3.1 グレースケール変換

一般的なカメラにより取得できる動画像を構成するのは24bitカラー画像である。24bitカラー画像の画素(pixel:ピクセル)は R , G , B (赤, 緑, 青)の3要素からなり、 RGB それぞれの要素が8bit(0~255)の256段階で表現される。このカラー画像に対して輝度値を利用したグレースケール変換を行うことで、黑白の濃淡(輝度)で表される画像に変換できる。輝度とは明るさの測度のことをいい、本論文ではNTSC(National Television System Committee)係数の加重平均法により算出する。輝度の値域は0~255となり、輝度値が0に近いほど画像は暗く、255に近いほど画像は明るくなる。 RGB 値を用いたNTSC係数による輝度値 L の算出式を式(2.1)に示す。

$$L = 0.299 \times R + 0.587 \times G + 0.114 \times B \quad (2.1)$$

2.3.2 エッジ抽出

エッジ抽出とは、画像中で画素値の変化が急峻であるエッジ部分を取り出す処理のことをいう。エッジ抽出のための手法として最も典型的なものは、画像の濃淡変化の微分値を利用する手法である。ここでの微分とは、 x 座標及び y 座標による画像の濃淡の変化分、すなわち空間微分のことである。デジタル画像では x 座標及び y 座標は離散的であり、整数値しか持たないため、数学的な一般式をそのまま適用できない。そのため、微分ではなく差分を用いる。この際、コンピュータ内でのデータの扱いやすさの観点から、一般には式(2.2), (2.3)に示すように、1画素において差分を計算することが行われる^[2-9]。

$$f_x = L(x + 1, y) - L(x - 1, y) \quad (2.2)$$

$$f_y = L(x, y + 1) - L(x, y - 1) \quad (2.3)$$

ここで、 $L(x, y)$ は座標 (x, y) における濃淡レベルを指す。

式(2.2), (2.3)に示した差分は、重み係数行列と画像データとの積和演算により求まり、この重み係数行列を拡張したものがフィルタ（局所積和演算重み係数行列）となる^[2-9]。

微分フィルタにはいくつか種類があるが、本論文では画像上の輪郭以外の部分、すなわち雑音を抑えながらエッジを抽出できる Sobel フィルタを用いる。Sobel フィルタによるエッジ抽出は、着目画素を中心とした 3×3 の9つの画素に対して図 2.3 に示す値を乗算し、方向毎に結果を合計する。 x 方向の結果を $sobel_x$ 、 y 方向の結果を $sobel_y$ とすると着目画素のエッジ強度 $sobel_{xy}$ は式(2.4)により求まる。

x 方向フィルタ（垂直成分）			y 方向フィルタ（水平成分）		
-1	0	1	1	2	1
-2	0	2	0	0	0
-1	0	1	-1	-2	-1

[] 着目画素

図 2.3 Sobel フィルタ

$$sobel_{xy} = \sqrt{sobel_x^2 + sobel_y^2} \quad (2.4)$$

また, Sobel フィルタの水平方向成分 $sobel_y(x,y)$ 及び垂直方向成分 $sobel_x(x,y)$ を用いることで, 式(2.5)よりエッジの方向 $\theta(x,y)$ が求まる。

$$\theta(x,y) = \arctan\left(\frac{sobel_x(x,y)}{sobel_y(x,y)}\right) \quad (2.5)$$

2.3.3 白線エッジの方向特徴を利用したエッジ抽出

エッジ抽出には, 2.3.2 項でも述べたとおり, 画像上の輪郭以外の部分である雑音を抑えながらエッジを抽出できる Sobel フィルタを用いる。ここで, 横断歩道や道路標示などのエッジは, 白線よりも垂直に近い方向成分を持つことから, エッジの方向を算出し, 文献[2-8]と同様にエッジを抽出する方向成分をより細かく限定することで, 雑音の抑制をはかる。図 2.4 に示す道路標示を含む画像を, 図 2.5 に道路標示を含む入力画像 (図 2.4) からエッジ強度を算出した画像を示す。算出するエッジ方向は, 図 2.5 に示すエッジ強度から式(2.5)により算出したのち, 図 2.6 に示す 16 のエッジ方向で量子化する。図 2.7 にエッジ強度を 16 のエッジ方向で色分けした画像を示す。



図 2.4 道路標示を含む入力画像



図 2.5 道路標示を含む入力画像からのエッジ強度抽出

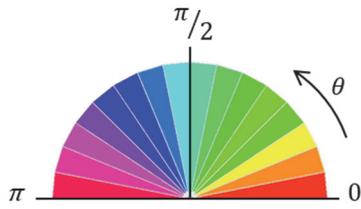


図 2.6 エッジの量子化方向

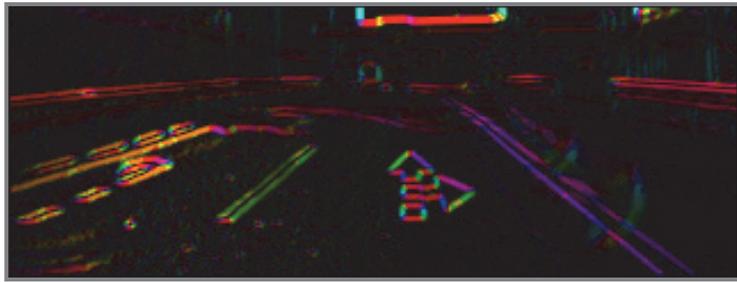


図 2.7 16 方向で量子化し色分けしたエッジ画像

図 2.7 に示したエッジ方向画像を下端から見ると、左白線は右上に向かって伸び、右白線は左上に向かって伸びるという特徴を持つ。これを利用して本論文では、画像中央より左側では右上方向のエッジ ($\pi/8 \leq \theta \leq 3\pi/8$)、右側では左上方向のエッジ ($5\pi/8 \leq \theta \leq 7\pi/8$) のみを抽出することとした。また、雨滴などの細かなエッジは方向がばらつきやすく除去が困難であるため、ガウシアンフィルタ (3×3) による平滑化を行ってからエッジ抽出を行うこととした。

図 2.8 に抽出を限定するエッジ方向を、図 2.9 に道路標示を含む入力画像 (図 2.4) に対する白線エッジの方向特徴を利用したエッジ抽出の画像例を示す。

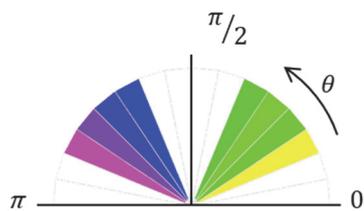


図 2.8 限定するエッジ方向

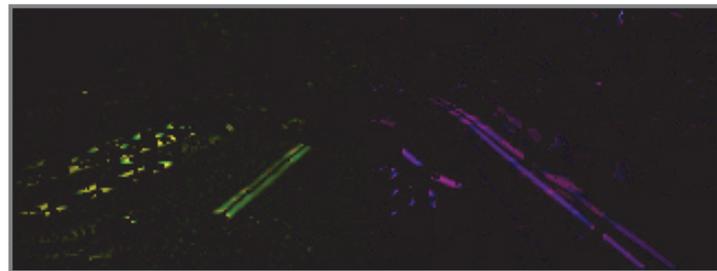


図 2.9 白線エッジの方向特徴を利用したエッジ抽出

抽出するエッジの斜め方向への限定は、2.1 節で述べたように適用可能な道路構造のシーンを狭め、斜め方向以外のエッジ成分を含むカーブへの対応が難しくなる。この問題について、まず図 2.10 に示すような高速道路など曲率半径の大きなカーブについて考えると、80m 遠方付近からは直線の白線と異なる方向成分を持つが、自車両近傍においては直線の白線と同様の方向成分を持つ。そのため、自車両近傍においては斜め方向に限定しても白線が抽出可能であり、本論文の処理領域限定という用途であれば問題はない。



図 2.10 曲率半径の大きなカーブシーン例（先行車両が 80m 遠方付近に存在）

次に図 2.11 に示すような一般道など曲率半径の小さなカーブについて考えると、カーブ特有の方向成分を持つエッジが多くなるため、方向限定を行うと白線候補点が抽出できなくなる。カーブの白線は直線の白線と異なり、自車両の前進に従って映り方が変化する。そのため、方向を限定せずに全方向のエッジを用いてカーブの白線エッジを抽出し 2.4 節に後述するエッジ重畳を行うと、図 2.11(b), (c) に示すようにカーブの白線エッジが太くぶれたような画像となる。これは抽出対象である白線に対して雑音が多く、白線の誤抽出に繋がると考えられる。本論文の場合は、方向を限定することで図 2.11(d) に示すようにカーブのエッジの重畳が抑制されて誤抽出が防げるが、図 2.11(d) の画像からでは白線が抽出できないため、処理領域限定としては 2.5.2 節に後述するログを用いた白線補完により補うこととなる。



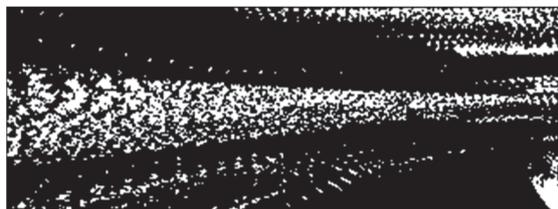
(a) カーブシーンの例



(b) 全方向のエッジ抽出画像



(c) 全方向のエッジ重畳画像



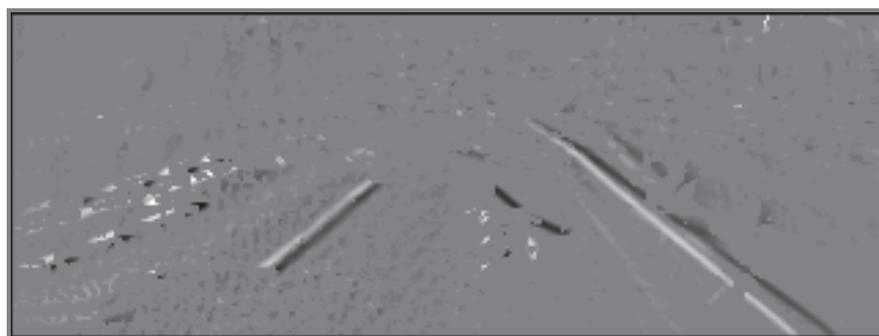
(d) 特定エッジ方向のエッジ重畳画像

図 2.11 曲率半径の小さなカーブシーンの例

2.3.4 白線エッジのピーク特徴を利用したエッジ選別

白線エッジの方向特徴を考慮しても、図 2.9 のように白線エッジと関係のない雑音が残ることがある。ここで、文献[2-5]にもあるように、路面上に描かれた白線の両端には、水平方向微分で、路面（暗）から白線（明）に向かう正のエッジのピークと白線（明）から路面（暗）に向かう負のエッジのピークが現れる。そこで、白線エッジの方向特徴を利用したエッジ抽出の際に正負のピーク情報を反映させておき、白線エッジの正負のピークペアの有無を利用したエッジの選別を行うことで、雑音の抑制をはかる。なお、道路標示も同様の特徴を持つが、ピークペアが現れる間隔が白線よりも広いものも多く、またエッジの方向が白線と異なる場合が多いため、多くの場合は区別可能と考える。

図 2.12 に、道路標示を含む入力画像（図 2.4）に対する正負のピーク情報を反映させたエッジ抽出の画像例を示す。なお、正のピークエッジを白、負のピークエッジを黒、エッジなしをグレーで表している。



白：正のピークの強度 黒：負のピークの強度

図 2.12 正負のピーク情報を反映させたエッジ抽出

具体的な処理としては、正負のピークを反映させたエッジ画像に対して左上から画素走査を行い、正のピークを発見したら、そのペアが存在すると考えられる右方向に探索範囲を設定し、その範囲内で負のピークを探索する。この探索により負のピークが見つかった場合のみ、白線エッジとして残す。ここで、道路白線の線幅は、画像上で下端に近づく（自車両に近い）ほど広く、上端に近づく（地平線に近い）ほど狭く撮影される。このことから、ピークペアを探索するために生成する行方向の探索領域のピクセルサイズ (*Filtersize*) を、*y*座標の値により変動するものとして式(2.6)により算出する。

$$Filtersize = Maxsize - \frac{y}{Imageheight} \times (Maxsize - m) \quad (2.6)$$

ここで、 y は画像を xy 座標系でみたときの y 座標を表し、 $Maxsize$ は $y = 0$ (画像最下端) における白線の幅を表す。本論文では、 $Maxsize = 15$ に設定した。 $Imageheight$ は画像の高さであり、 y のとり得る最大値である。 m は $Filtersize = 0$ となることを防ぐものであり小さい値で設定する。本論文では $m = 2$ とした。

表 2.1 に白線エッジのピーク特徴を利用したエッジ選別の処理手順を、図 2.13 に白線エッジのピーク特徴を利用したエッジ選別の概念図を示す。また、図 2.14 に白線エッジのピーク特徴を利用したエッジ選別の処理例を示す。

表 2.1 白線エッジのピーク特徴を利用したエッジ選別の処理手順

Step1 :	① 画像左上から右下に向かって画素走査 (ラスタスキャン) を行う
Step2 :	正のピークを発見したら行方向に探索領域を作成し、負のピークを探索する
Step3 :	② 負のピークが発見できれば、正のピークエッジを白線エッジとして抽出する ③ 負のピークエッジが発見できなければ、白線エッジでないとして除去する
Step4 :	全ての画素を走査したら終了する

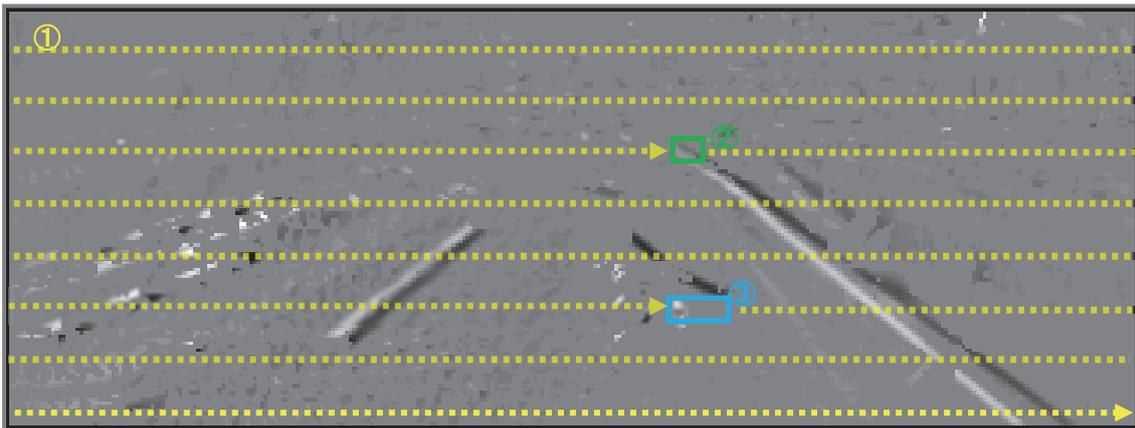


図 2.13 白線エッジのピーク特徴を利用したエッジ選別の概要



図 2.14 白線エッジのピーク特徴を利用したエッジ選別

2.3.5 白線エッジの方向特徴を利用したエッジ補正

白線エッジの方向特徴やピーク特徴を考慮しても、わずかな雑音が残ることがある。一枚のみではわずかな雑音であっても、後述するエッジ重畳を行うと大きな雑音となることがあるため、この雑音の除去を行う。雑音除去の手法はいくつか考えられるが、本論文ではモルフォロジー演算による雑音除去を検討する。

(1) モルフォロジー演算

モルフォロジー (morphology) 演算とは、構造化要素と基本演算で定義されるものであり、演算が容易であることから雑音除去や平滑化など様々な目的で用いられる^[2-11]。

構造化要素とは、画像処理におけるフィルタを指し、着目画素とその近傍画素を含めた任意の形状で設計することができる。よく知られているものとしては、 3×3 の disk (4 近傍) や square (8 近傍) がある。図 2.15 に構造化要素の例を示す。

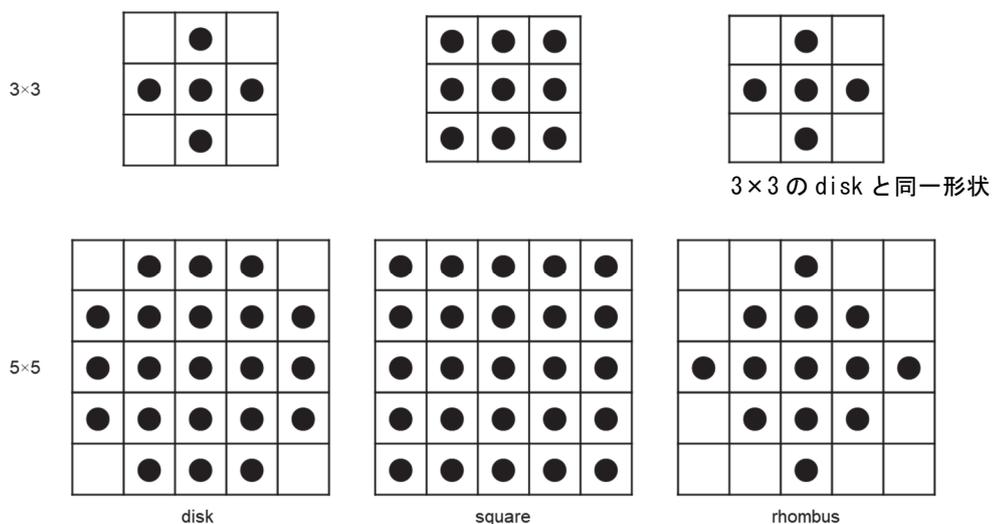


図 2.15 構造化要素の例

基本演算とは、構造化要素を用いた画像の集合演算として定義され、dilation（膨張）、erosion（収縮）、opening、closing といった演算の種類がある。2 値画像に対する処理と、多値画像に対する処理があるが、ここでは2 値画像に対する処理について述べる。

図 2.16 に示すように、膨張処理は原画像 A の全ての点を構造化要素 A の基点（今回は左上の点とする）でなぞったときの、構造化要素 A の軌跡に相当する。

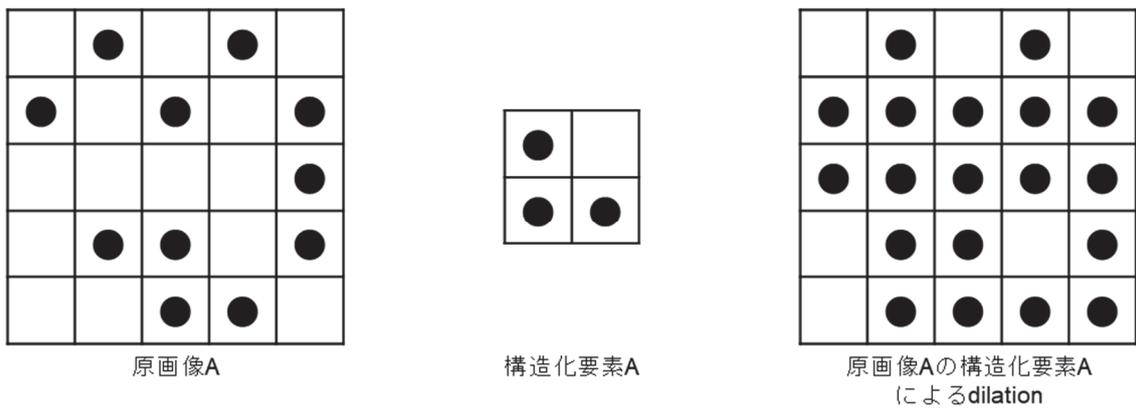


図 2.16 膨張処理の例

図 2.17 に示すように、収縮処理は原画像 B の全ての点を構造化要素 A がはみ出さないようになぞったときの、構造化要素 A の基点（今回は左上の点とする）の軌跡に相当する。

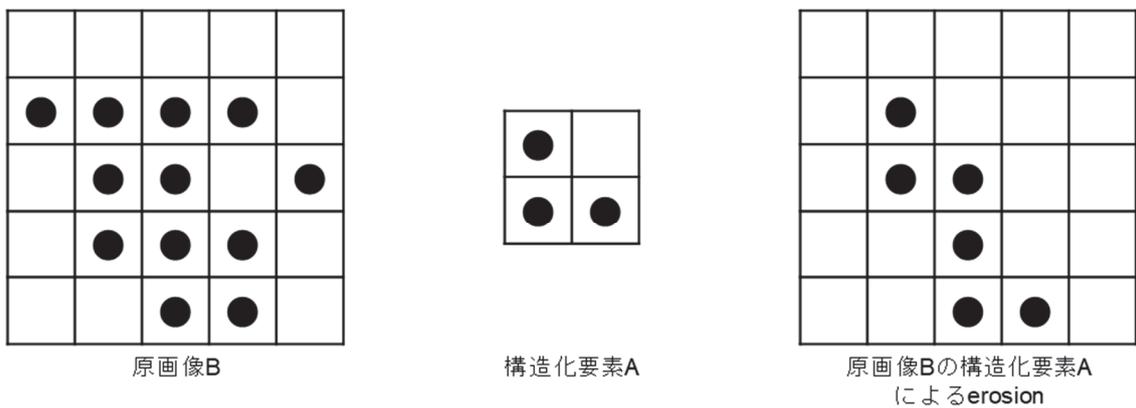


図 2.17 収縮処理の例

(2) モルフォロジー演算を利用した雑音除去及びエッジ補正

エッジ選別を行った後の画像では、図 2.14 に示すように孤立雑音が多いため、 3×3 の square を用いて収縮処理を行い孤立雑音の除去をはかる。図 2.18 にエッジ選別の後に 3×3 の square を用いた収縮処理を行った画像を示す。



図 2.18 エッジ選別後に 3×3 の square を用いた収縮処理

square を用いた収縮処理は画像全体に働くため、残したい白線エッジ部分も除去の対象となる。この影響を緩和するために、0 項で示した左右白線の方向特徴を用いて、限定した方向と同等の方向を持つエッジを強調する 3×3 の構造化要素 Line (図 2.19) を設計し、画像中央から左には右上 (左下) 方向の Line を、右には左上 (右下) 方向の Line を用いた膨張処理を行うことで、収縮処理により除去された白線エッジに対する補正を行う。図 2.20 に、白線エッジの方向特徴を利用したエッジ補正を行った画像例を示す。

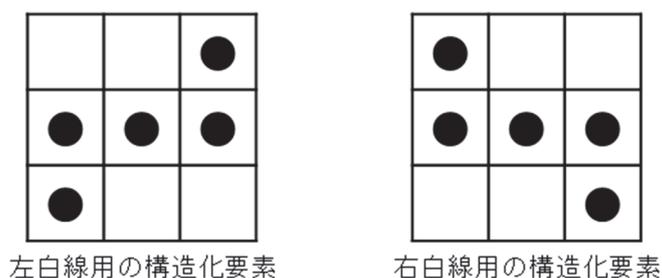


図 2.19 構造化要素 Line



図 2.20 白線エッジの方向特性を利用したエッジ補正

2.4 リングバッファを用いたエッジ重畳

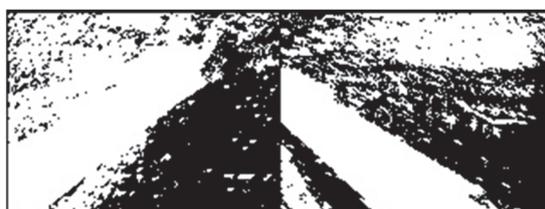
道路上の白線には、破線状のものやペイントがかすれ状態になっているものがあり、通常のエッジ抽出では白線エッジに途切れが生ずる。一般的な白線抽出のアプローチは Hough 変換などにより、これらのエッジ点から直線を抽出する方法であるが、エッジ点が少ない場合一つ一つの寄与が大きくなるため、より頑健性の高いエッジ抽出が要求される。

これに対し本論文では、連続するフレームにおいて画像上での白線位置に変化が少ないことを利用し、あるフレーム区間（現フレームから過去数十フレーム）のエッジ画像を重ね合わせることで破線やペイントかすれにより途切れている白線エッジを連続した画素塊に補完する、エッジ重畳を検討する。

エッジ重畳を続けていくと、図 2.21 に示すように重畳画像が白画素で埋まり、もとのエッジの形状が失われるため白線抽出が困難となる（エッジ過重畳とする）。



(a) エッジ画像



(b) エッジ重畳画像

図 2.21 エッジ過重畳例

エッジ過重畳を防ぐためには、数フレームごとにバッファのリセットが必要となる。しかし、単純なバッファのリセットでは、リセット直後にエッジ重畳が十分にされておらずエッジは途切れたままとなる。

この問題に対し本論文では、リングバッファ構造 (図 2.22) を応用したエッジ重畳を提案する。まず、エッジ重畳に用いる画像 N 枚分のバッファを確保する。バッファ内で最古のエッジ画像を最新のエッジ画像で上書きしながら循環的に利用することで、常に一定かつ最新のエッジ画像 N 枚を用いたエッジ重畳を可能にする。

表 2.2 にリングバッファを用いたエッジ重畳の処理手順を示す。また図 2.23 に、重畳フレーム数を N としたときの、リングバッファを用いたエッジ重畳の概念図を示す。

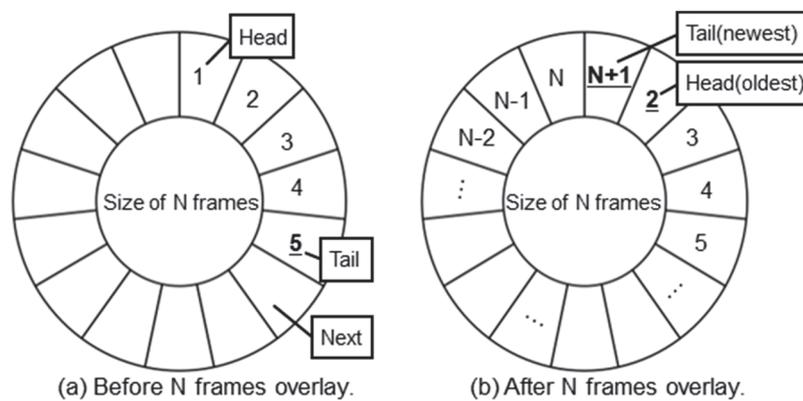


図 2.22 リングバッファ構造

表 2.2 リングバッファを用いたエッジ重畳の処理手順

Step1:	①	重畳フレーム数に達するまで到着順に重畳を行い、重畳できているフレーム分の重畳画像に対して白線抽出を行う
Step2:	②	重畳フレーム数に達したら、重畳フレーム分の重畳画像に対して白線抽出を行う
Step3:	③	新しいフレームが到着したら、バッファの中で最も古いフレームを新しいフレームで置き換え、重畳フレーム分の重畳画像に対して白線抽出を行う
Step4:		Step3 を繰り返し実行する

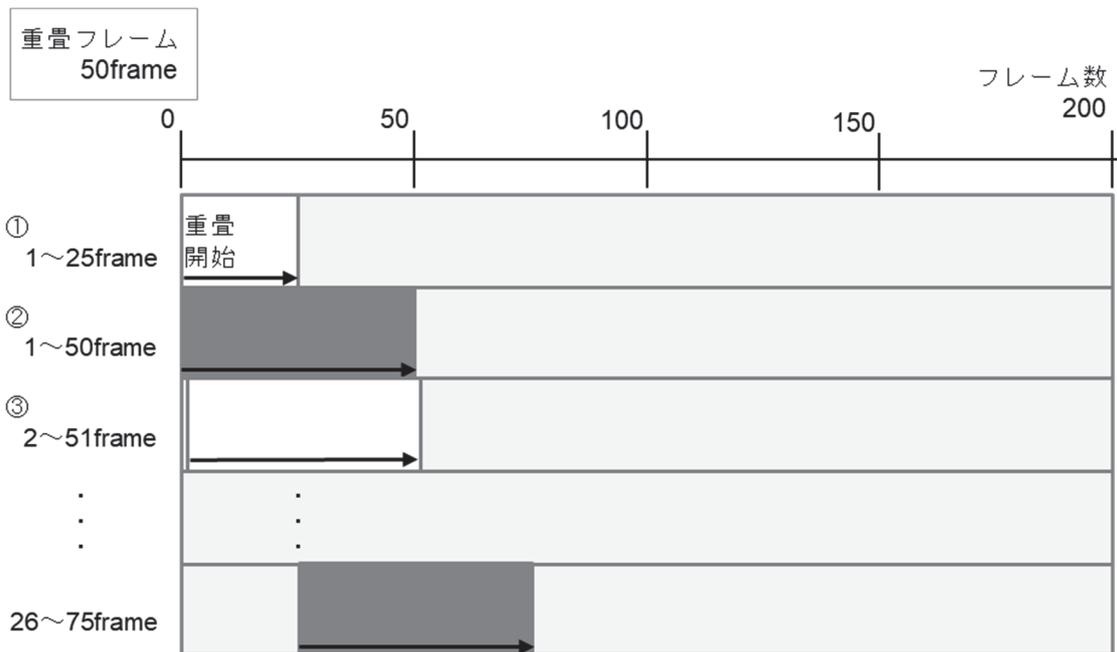


図 2.23 リングバッファを用いたエッジ重畳の概念図：重畳フレーム数 50 の例

白線エッジ特徴を利用して雑音抑制をはかっても、横断歩道など、白線に類似した特徴を多く含む雑音は、完全な除去が困難である。こうした雑音が抽出されていた場合、エッジ重畳により雑音が強調され誤抽出につながる問題がある。そのため、適切な重畳フレーム数の設定が必要となる。ここで、エッジ重畳の目的の一つは、破線状の白線を補完することである。道路を L [m]進むのに要するフレーム数 $RFrames$ [frame]は、自車両走行速度 v [m/s]とフレームレート F [fps]から、(2.7)式により求まる。

$$RFrames = \frac{L \times 3.6 \times F}{v} [\text{frame}] \quad (2.7)$$

エッジ重畳により補いたい破線の間隔は、国内の一般道及び高速道路においてそれぞれ表 2.3 に示す値である。表 2.3 の白線間隔の値を式(2.7)の L に代入し、自車両走行速度に対する破線の間隔を補うために必要なフレーム数を算出したグラフを図 2.24 に示す。

表 2.3 破線状の白線の寸法

	白線長 [m]	白線間隔 [m]
一般道	5	5
高速道路	8	12

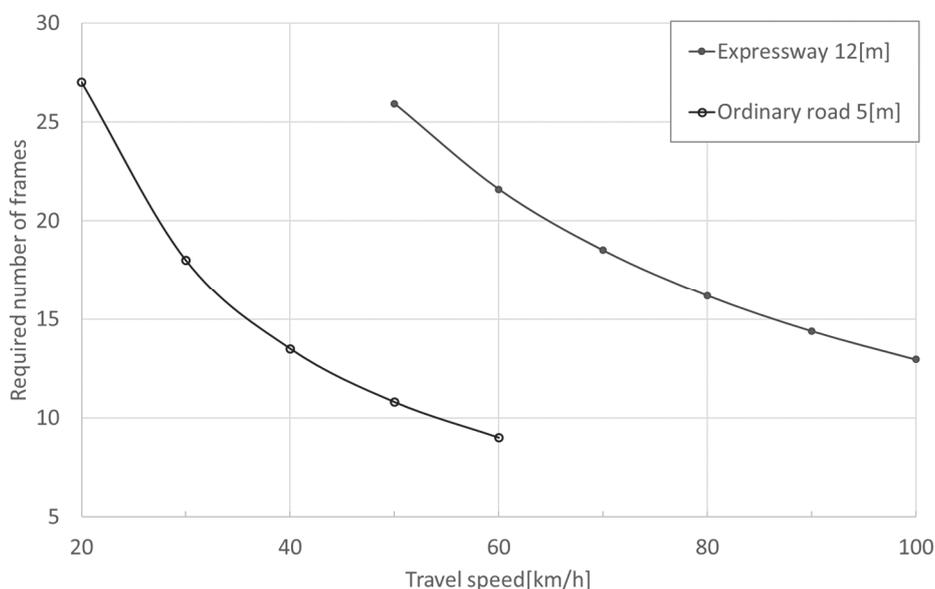


図 2.24 走行速度に対する破線間隔を補うために必要な走行フレーム数

構造をシンプルにするため、本論文では重畳フレーム数を、破線の間隔を補うのに最もフレームを要する通常走行とみなせる最低速度をもって算出することを考える。通常走行とみなせる最低速度は、一般道では警察庁が非渋滞とする最低速度の 20km/h、高速道路では法定最低速度の 50km/h とする。図 2.24 より、破線の間隔を埋めるのに必要なフレーム数は一般道で 27frame、高速道路で 26frame となる。これらの値は破線の間隔分と同等であるため、自車両走行速度のばらつきや、若干の蛇行によりエッジが重畳画像上で連結しない恐れがある。そのため本論文では、破線が現れてから次の破線が現れるまでを 1 周期（一般道では 10m、高速道路では 20m）とし、これを重畳フレーム数に設定する。図 2.25 に、走行速度に対する破線 1 周期分を補うために必要な走行フレーム数のグラフを示す。

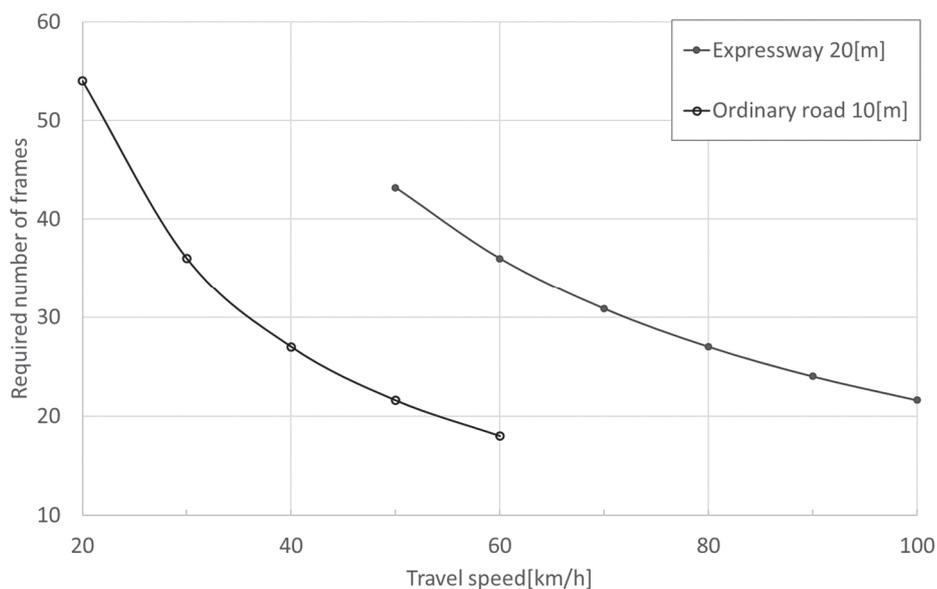


図 2.25 走行速度に対する破線 1 周期分を補うために必要な走行フレーム数

図 2.25 より一般道では走行速度 20km/h において 54frame, 高速道路では走行速度 50km/h において 43frame となるが, 重畳フレーム数を道路種別によって切り替えず一律で一般道及び高速道路に対応することを考え, 大きい方の 54frame を重畳フレームとして採用する。なお, 高速道路は一般道よりも雑音となる道路標示などが少ないことから, 1 周期分よりも余分に重畳する影響は少ないと考える。さらに, 一般に車載カメラは車両中央に設置するため, 道路の中央に描かれる道路標示は画像中央付近に存在する。よって, 画像左右端の重畳フレーム数を 54frame に設定し, 画像中央に近づくほど減少させ, 最も少ない画像中央で約 40% の 21frame に設定することで, 道路標示のエッジの強調を抑制することとする。

2.5 連結画素走査

白線抽出の手法として、白線のエッジを含むエッジの2値化画像を利用し、白線の特徴である直線性に着目して直線抽出を行う Hough 変換が多く用いられてきた。しかし、Hough 変換は演算量が多く、直線を構成するための十分なエッジ点が得られている必要があることに加え、抽出した直線のうちどれが白線であるかを選別する必要がある。さらに、本論文で作成するエッジ重畳画像に対して Hough 変換により直線を抽出することも可能ではあるが、細線化しないことより多数の直線が抽出されるため、本論文では連結画素走査を用いた白線抽出を提案する。連結画素走査は画像全体を走査するのではなく、画像の下部から上部（消失点）に向かって伸びているという白線の特徴を利用して白線付近をダイレクトに走査する手法である。表 2.4 に連結画素走査の処理手順を、図 2.26 に概念図を示す。

連結画素走査ではまず、2 値化後のエッジ抽出画像に対して画像中央の下部から左右の白線に向かって走査し、白画素を発見したらそこから上方 3 近傍へ向かって走査を行う。このとき、常に上に向かって進むと抽出できる白線の角度が限定されるため、上方 3 近傍への走査の前に横への白画素の連結の有無を調べ、横に連結する成分がある場合は横に移動してから上方 3 近傍への走査を行うこととした。画素走査により連結数が一定数以上になれば、走査した白画素を白線とみなして抽出する。画像中央から走査する理由は、画像の左右端から走査するよりも雑音の影響を抑えられるためである。

また、道路形状変化や車体の動きによる瞬発的なエッジはエッジ重畳画像に対して連結画素走査を行うと捉えられない場合がある。ここで、エッジ重畳は白線抽出が行えないほどかすれた場合や破線への対応である。そこで、最初に左右それぞれで現フレームのエッジ画像に対する連結画素走査を行い、十分な連結数が得られない場合にのみエッジ重畳画像に対する連結画素走査を行う二段階構成（二段階連結画素走査と呼ぶ）とする。さらに、現フレームのエッジ画像から連結画素走査により白線を抽出できた場合は現フレームのエッジ画像を用いてエッジ重畳画像のリセットを行う構造とした。これにより、瞬発的なエッジの変化をエッジ重畳画像へ反映させることが可能となる。このとき、現在のエッジ画像から白線が抽出できるかどうかは左右白線で異なるため、エッジ重畳を行うバッファを左右で分割することとした。

表 2.4 連結画素走査の処理手順

Step1 :	画像下端中央に着目点を設定する
Step2 :	① 白画素を発見するか端に達するまで左(右)に向かって着目点を動かしながら画素走査を行う
Step3 :	白画素を発見した場合, 着目点を固定して Step4 へ, 端に達した場合 Step7 へ
Step4 :	② 右(左), 上方3近傍{右(左)上, 上, 左(右)上}の順で画素走査を行う
Step5 :	③ 白画素が途切れるまで Step4 を繰り返す
Step6 :	走査した白画素が一定数以上連結していれば, その連結成分を白線とみなして抽出し処理を終了する。一定数未満であれば Step2 へ
Step7 :	画像上端でなければ着目点を一行上の中央に設定し, Step2 へ。画像上端であれば白線が存在しないとして処理を終了する

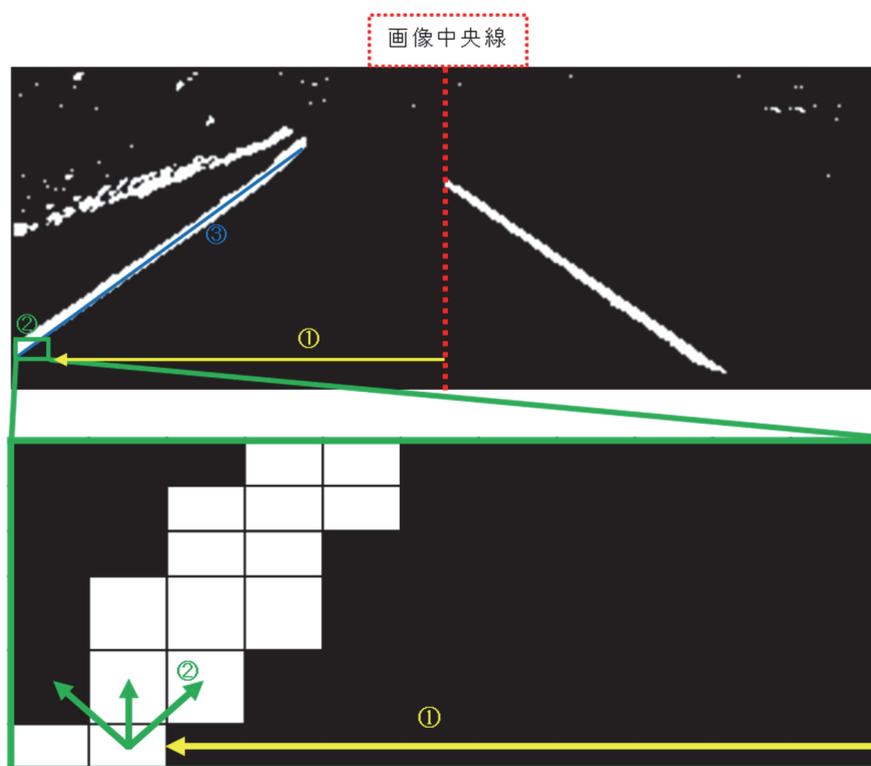


図 2.26 連結画素走査の概念図

2.5.1 連結画素走査を利用した直線近似

連結画素走査はエッジ重畳画像上で白線らしい性質を持つように連結するエッジ点を抽出する手法である。この手法は左右ジグザグな連結も許容して抽出するため、得られる結果は画像上の白線の傾きなどを正確に捉えられないことがある。またエッジ重畳画像は自車両の動きやカーブなどにより実際の白線よりも太くなり、これは連結画素走査による白線抽出結果が実際の白線とずれる、形状が安定しない、などの問題につながる。図 2.27 に実際の白線とずれが生じている連結画素走査の画像例を示す。

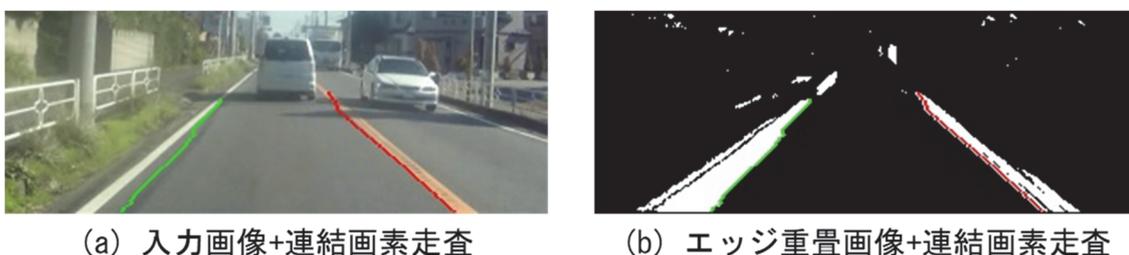


図 2.27 実際の白線とずれが生じた連結画素走査の例

ここで連結画素走査により白線近傍のエッジ点を抽出できた場合、抽出した画素の近傍には白線を構成するエッジ点の塊があることが期待できる。よって、連結画素走査により抽出した画素の近傍のエッジ点の塊から直線近似により近似直線を求めることでより実際の白線に即した白線抽出が可能と考え、本論文では連結画素走査を利用した直線近似による白線抽出を行う。図 2.28 に、図 2.27 の連結画素走査の結果を利用して求めた直線近似に用いるエッジ点の探索範囲を表した画像を示す。

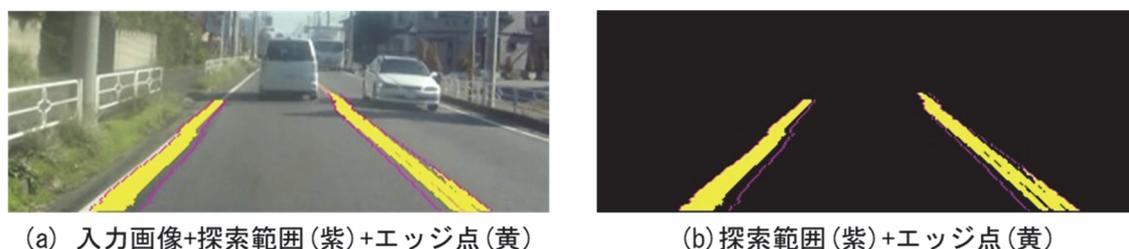


図 2.28 直線近似に用いるエッジ点の探索範囲

直線近似を実現する手法として代表的なものに、最小二乗法と主成分分析がある。最小二乗法とは、点データの集合と y 軸方向の距離（残差の二乗和）を最小にする直線が得られる手法である。主成分分析とは、複数の変数間の相関を、より少ない数の主成分という合成変

数で表現（次元縮約）する手法であり，画像処理における直線近似では，点データの集合から引いた垂線距離を最小にする直線が得られる^[2-12]（図 2.29）。

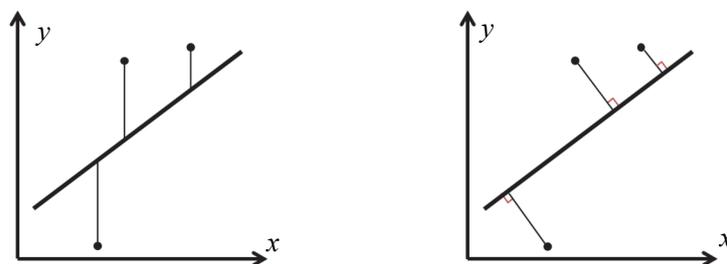
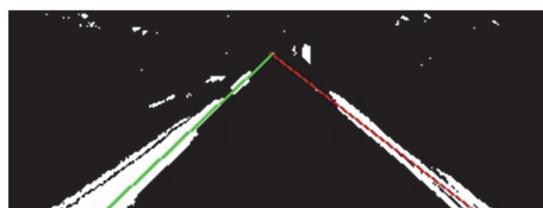


図 2.29 最小二乗法（左）と主成分分析（右）

x 軸と y 軸を平等に扱う主成分分析の方がより適切な直線を近似できるため，本論文では主成分分析を採用する。図 2.30 に連結画素走査を用いた直線近似の画像例を示す。



(a) 入力画像+近似直線



(b) エッジ重畳画像+近似直線

図 2.30 連結画素走査を用いた直線近似

2.5.2 ログを用いた白線補完

本論文の白線抽出は，連結画素走査の結果を利用するため，連結画素走査において一定数以上連結した白画素が発見できなければ，白線は未抽出となる。白線抽出は，以後の処理領域を限定するために用いることから，本論文では，白線抽出が成功した前フレームにおける白線の位置情報をログとして取得しておき，白線が未抽出となった際の救済としてログを用いた白線補完を行う。

ログとして取得するのは抽出した左右白線の始点（画像下端）の座標 2 点と，左右白線の終点（交点）座標の計 3 点とした。取得した始点と交点をそれぞれ結ぶことで処理領域とし，取得する点を 3 点のみとすることで抽出した白線情報全体を保持するよりも処理の効率を向上できる。

2.6 白線抽出実験

白線エッジ特徴を考慮したエッジ重畳による白線抽出の有効性を検証するために提案手法のほか3つ比較手法を用いて白線抽出実験を行う。なお、実験で使用する白線の正解データは、テスト用動画像から左右の白線を構成する画素を手動で抽出し、左右の白線画素それぞれに対して主成分分析による直線近似を行うことにより作成した。

2.6.1 実験条件

実験の諸条件を以下に示す。

○PCの仕様

実験には以下の構成のPCを使用した。

- CPU : Intel Core i7-6800K 3.4GHz
- RAM : 32GB
- OS : Windows 10

○実験シーン（動画）：QVGA（320×240 pixel），30 fps

実験には以下のシーンを使用した。

- 高速道路 昼 晴天 左白線：実線 右白線：破線 1シーン 530frames
- 一般道 夜 雨天 左白線：実線 右白線：破線 1シーン 470frames
- 一般道 昼 雨天 左白線：破線 右白線：実線 1シーン 534frames

○比較条件

比較条件は表 2.5 のとおりとした。なお、全ての手法において連結画素走査を用いた直線近似、ログを用いた白線補完は行うものとする。また連結画素走査において白線とみなす連結画素数の閾値は、試験的に求めた値の 38 とした。

表 2.5 提案手法と比較手法

手法	エッジ抽出手法	リングバッファを用いたエッジ重畳	連結画素走査
提案手法	白線エッジ特徴	重畳フレーム数可変	二段階
比較手法 A	Sobel フィルタの垂直成分	重畳フレーム数可変	二段階
比較手法 B	白線エッジ特徴	重畳フレーム数可変	一段段階 (エッジ重畳画像から)
比較手法 C	白線エッジ特徴	重畳フレーム数一定	二段階

○評価方法

本実験では、正解白線と抽出した白線との x 座標の差を求め全フレームの平均及び最大の誤差を用いて評価を行う。また、各フレームで x 座標誤差を白線の高さで割って平均化し、フレームを横軸、平均誤差を縦軸とした曲線を用いて手法の評価を行う。

2.6.2 実験結果及び考察

(1) 高速道路昼晴天シーンにおける実験結果の比較

表 2.6 に高速道路昼晴天シーンにおいて左右白線の平均 x 座標誤差, 最大 x 座標誤差及び平均処理時間をまとめた実験結果を, 図 2.31 に各手法における白線抽出結果の例を示す。また, 図 2.32 に 1 フレーム目から 300 フレーム目までを抜粋した各フレームにおける x 座標誤差の平均値の推移を示す。

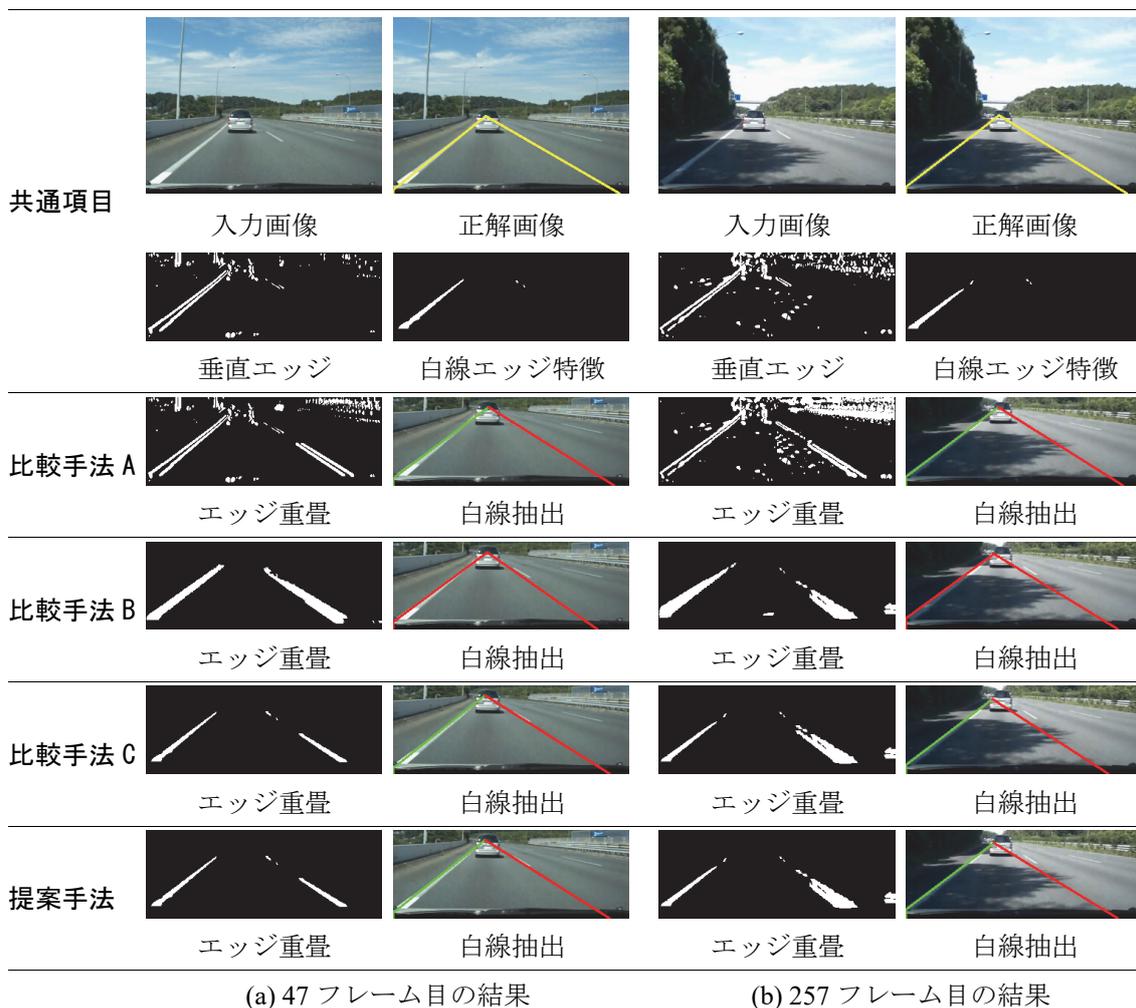
本実験シーンは, 道路標示等のペイントは存在しないが, 道路脇の木々の影によるエッジが路面上に生じるものを使用した。表 2.6 より, 白線エッジ特徴を考慮しない比較手法 A が左右白線ともに平均 x 座標誤差が最小である。しかし, 左白線の最大誤差については白線エッジ特徴を考慮する比較手法 C 及び提案手法が最小になった。

図 2.32(b)で, 47 フレーム目付近において比較手法 B の右白線の誤差が大きくなる。これは, 緩やかな左カーブを通過後のフレームであり図 2.31(a)に示すように重畳された左カーブのエッジの影響がバッファ上に残っているため実際よりも左に傾いた右白線として抽出したことが要因である。その他の手法においては二段階連結画素走査を用いることでカーブ後の直線のエッジにより早く対応でき, 誤差が小さくなった。

さらに図 2.32(b)で, 257 フレーム目付近において比較手法 A 以外の右白線の誤差が大きくなる。これも, 緩やかな左カーブを通過後のフレームであり, 重畳された左カーブのエッジの影響がバッファ上に残っているため図 2.31(b)に示すように実際よりも左に傾いた右白線として抽出したことが要因である。画像中の x 座標で重畳フレーム数を変更する比較手法 B 及び提案手法においては, 比較手法 C と比べ古い左カーブエッジの影響を抑制でき, フレーム内の平均誤差を 8pixel 程度減少させ, 12pixel 程度に収められた。比較手法 A については, 直前のフレームにおいて 1 枚の垂直エッジ画像から白線が抽出でき, バッファをリセットできたため影響を受けず, フレーム内の平均誤差が 3pixel 程度に収まった。

表 2.6 高速道路昼晴天シーンにおける実験結果

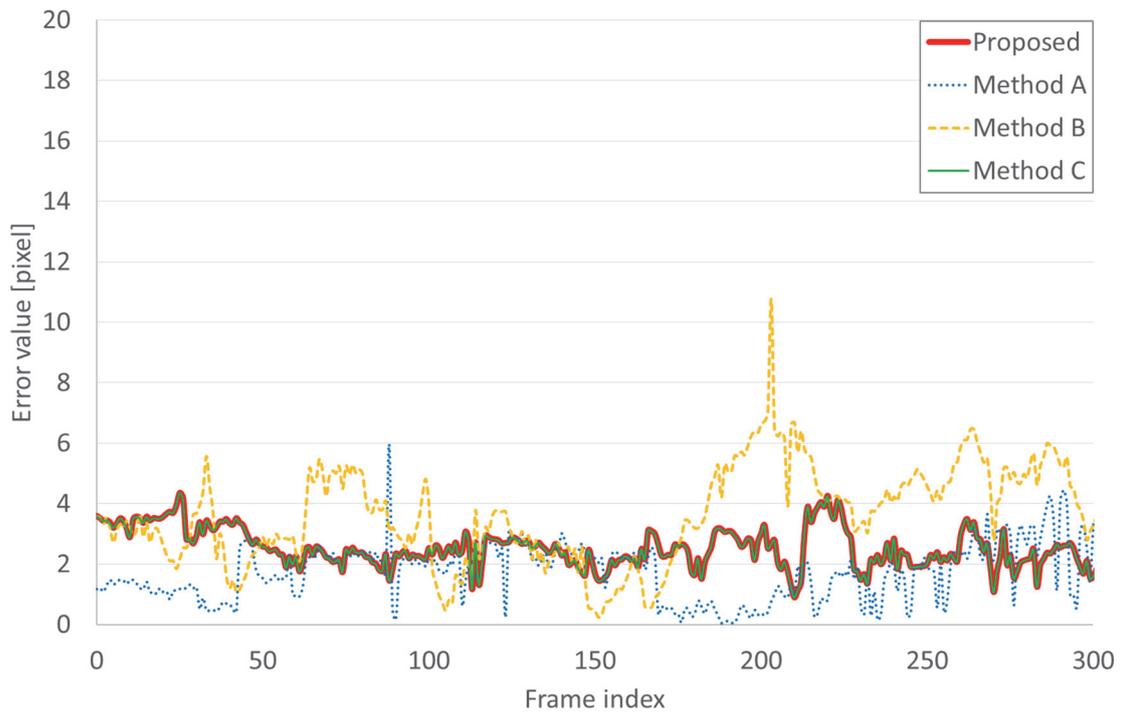
	比較手法 A	比較手法 B	比較手法 C	提案手法
左白線の全体平均 x 座標誤差 [pixel]	1.96	3.27	2.55	2.55
左白線の最大 x 座標誤差 [pixel]	14	16	8	8
右白線の全体平均 x 座標誤差 [pixel]	2.79	3.77	3.50	3.39
右白線の最大 x 座標誤差 [pixel]	18	31	25	21
平均処理時間 [ms]	1.65	1.00	2.17	2.04



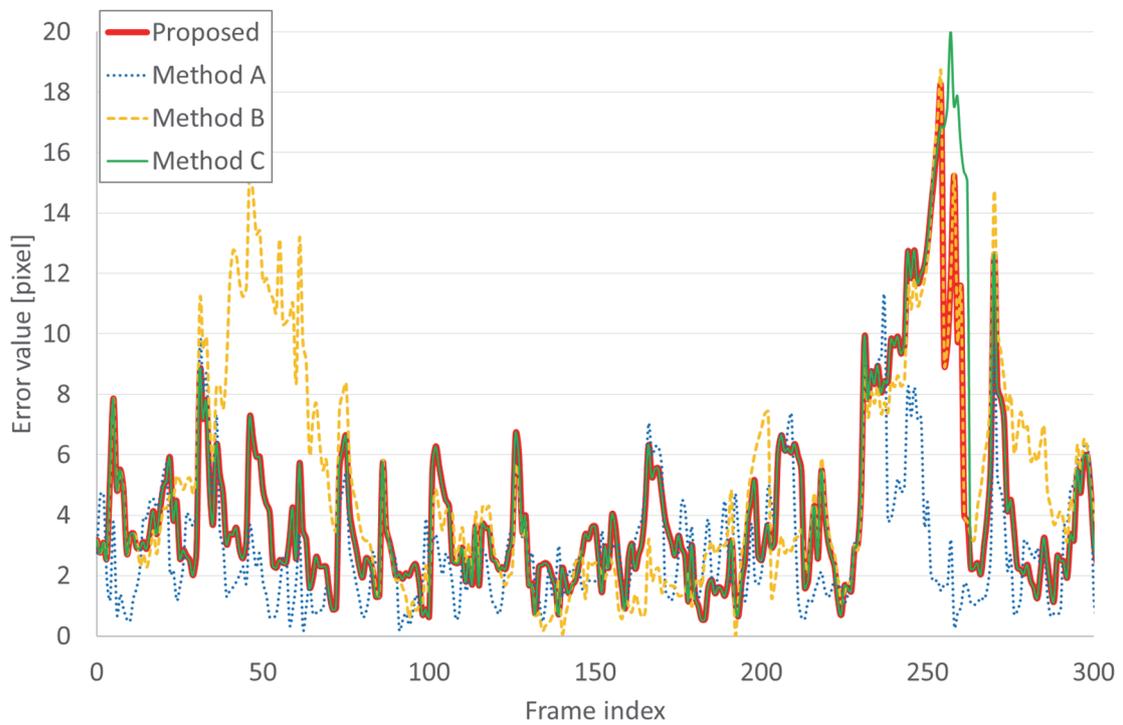
黄色線：正解白線

緑線：エッジ画像から抽出 赤線：エッジ重畳画像から抽出

図 2.31 高速道路昼晴天シーンにおける白線抽出結果例



(a) 左白線



(b) 右白線

図 2.32 高速道路昼晴天シーンにおけるフレーム毎の平均 x 座標誤差の推移

(2) 一般道夜雨天シーンにおける実験結果の比較

表 2.7 に一般道夜雨天シーンにおいて左右白線の平均 x 座標誤差, 最大 x 座標誤差及び平均処理時間をまとめた実験結果を, 図 2.33 に各手法における白線抽出結果の例を示す。また, 図 2.34 に 170 フレーム目から 470 フレーム目までを抜粋した各フレームにおける x 座標誤差の平均値の推移を示す。

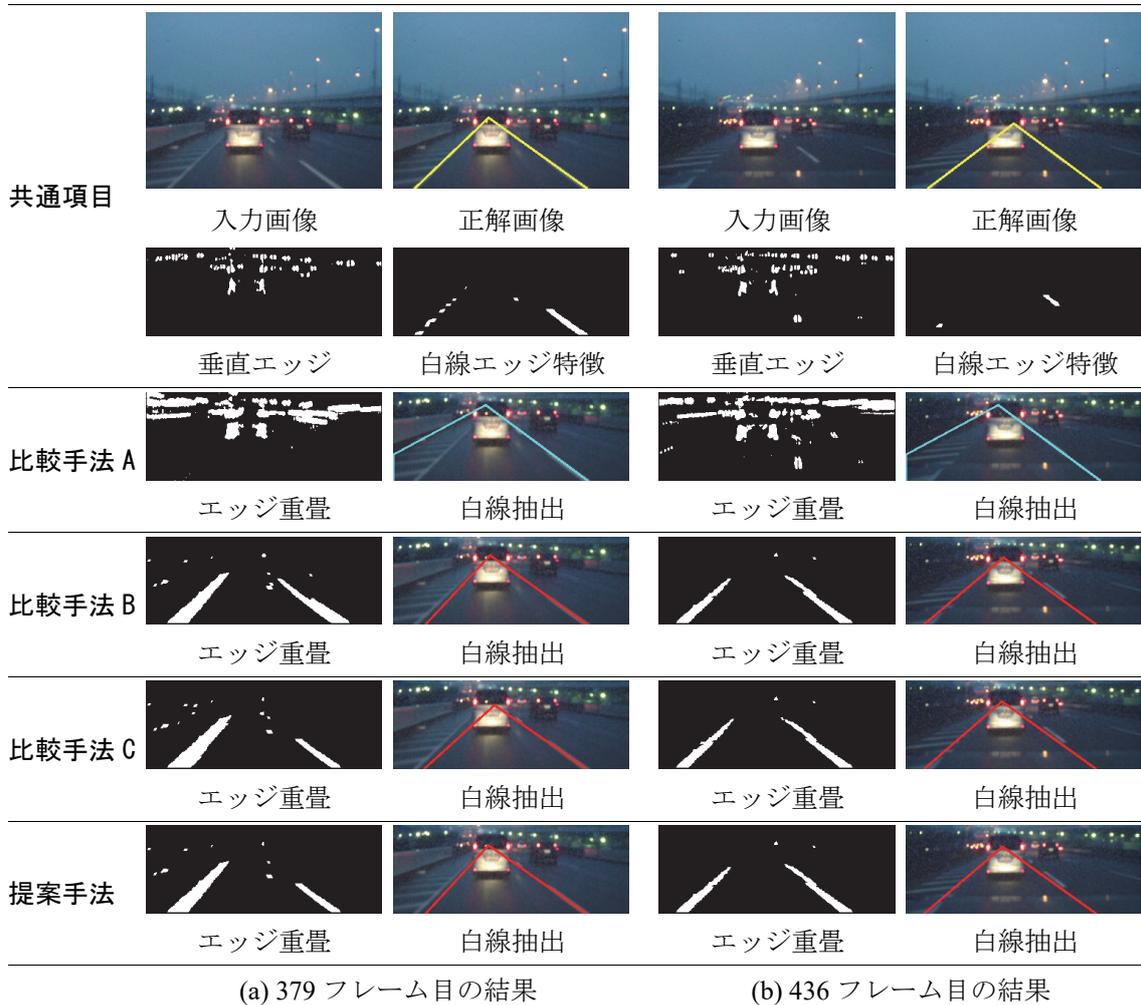
本実験シーンには, 左白線が雨に濡れることで反射して見えにくくなっていたり, かすれていたりするものを使用した。表 2.7 より, 提案手法が左白線の平均 x 座標誤差, 及び左右白線の最大 x 座標誤差が最小である。右白線の平均 x 座標誤差については比較手法 B が 2.30pixel と最も低いものの差は 0.01pixel となった。

比較手法 A は x 方向の Sobel フィルタにより抽出した垂直エッジの強度から判別分析法 (大津の閾値) により二値化しているが, 本シーンにおいては白線のエッジが他のエッジに比べて弱いため左白線を抽出できず, 平均誤差が 48pixel となった。よって図 2.34(a)において比較手法 A は表示していない。図 2.34(a)より, 380 フレーム目付近において, いずれの手法も左白線の誤差が大きくなっている。これは, 自車両が右に軽くハンドルを切っている最中のフレームであり, 図 2.33(a)に示すように実際の白線が重畳されているエッジよりも左に推移し, 対応しきれなかったことが要因である。しかし, 比較手法 C と比べると, 重畳フレーム数を x 座標に応じて変更する比較手法 B 及び提案手法では古いエッジの影響を抑え, 左白線の最大誤差を 5pixel 小さくできた。

さらに図 2.34(b)より, 430 フレーム目付近において, 比較手法 C 及び提案手法の右白線の平均 x 座標誤差が 10pixel 程度まで大きくなっている。これは 380 フレーム目付近で右にハンドルを切った後左に切り, 再度右にハンドルを切る軽い蛇行の最中であり, 図 2.33(b)に示すように二段階連結画素走査により蛇行途中の白線を捉えてバッファをリセットしたことが逆効果となり, 比較手法 B よりも平均誤差が 2pixel 程度大きくなった。なお, 比較手法 A の誤差が 0.5pixel 程度となっているが, 図 2.34(b)に示すようにバッファのなかに白線のエッジを抽出できていない状態で, ログが良好に適合した結果である。

表 2.7 一般道夜雨天シーンにおける実験結果

	比較手法 A	比較手法 B	比較手法 C	提案手法
左白線の全体平均 x 座標誤差 [pixel]	48.44	3.78	4.48	3.69
左白線の最大 x 座標誤差 [pixel]	90	18	23	18
右白線の全体平均 x 座標誤差 [pixel]	4.48	2.30	2.48	2.31
右白線の最大 x 座標誤差 [pixel]	28	17	16	16
平均処理時間 [ms]	1.89	1.02	1.72	1.85



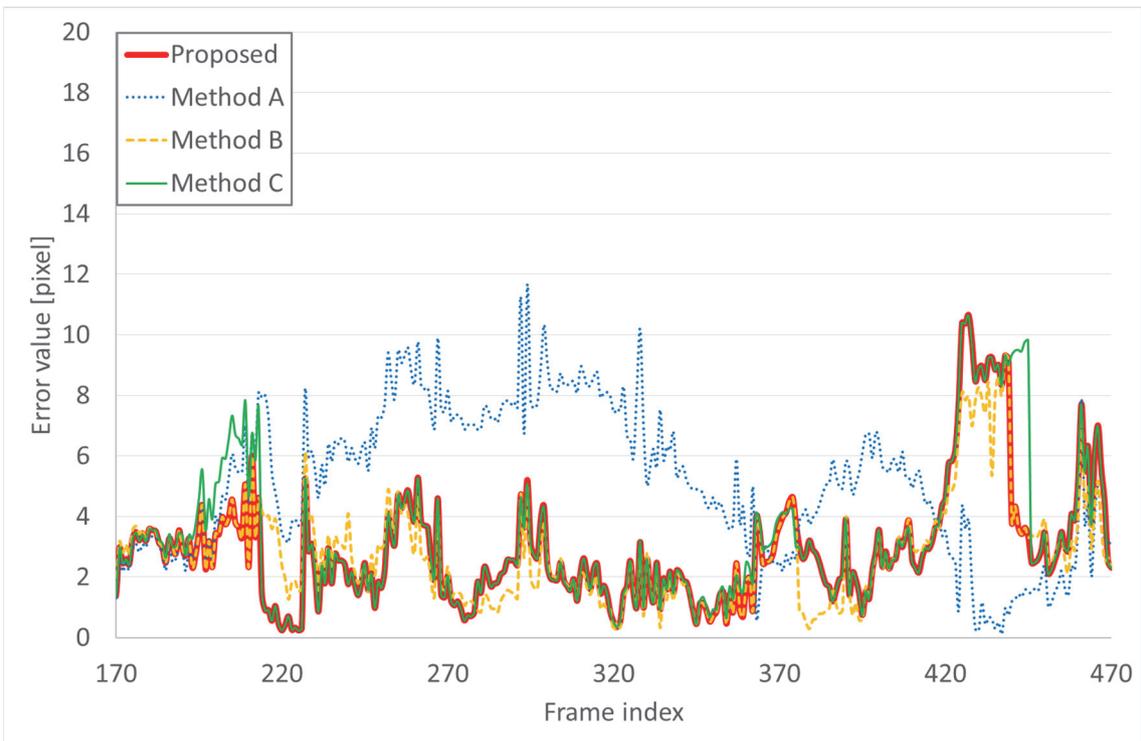
黄色線：正解白線

緑線：エッジ画像から抽出 赤線：エッジ重畳画像から抽出 青線：ログから抽出

図 2.33 一般道夜雨天シーンにおける白線抽出結果例



(a) 左白線：比較手法 A は Error Value 20[pixel]よりも大きく範囲外のため省略



(b) 右白線

図 2.34 一般道夜雨天シーンにおけるフレーム毎の平均 x 座標誤差の推移

(3) 一般道昼雨天シーンにおける実験結果の比較

表 2.8 に一般道昼雨天シーンにおいて左右白線の平均 x 座標誤差, 最大 x 座標誤差及び平均処理時間をまとめた実験結果を, 図 2.35 に各手法における白線抽出結果の例を示す。また, 図 2.36 に 70 フレーム目から 370 フレーム目までを抜粋した各フレームにおける x 座標誤差の平均値の推移を示す。

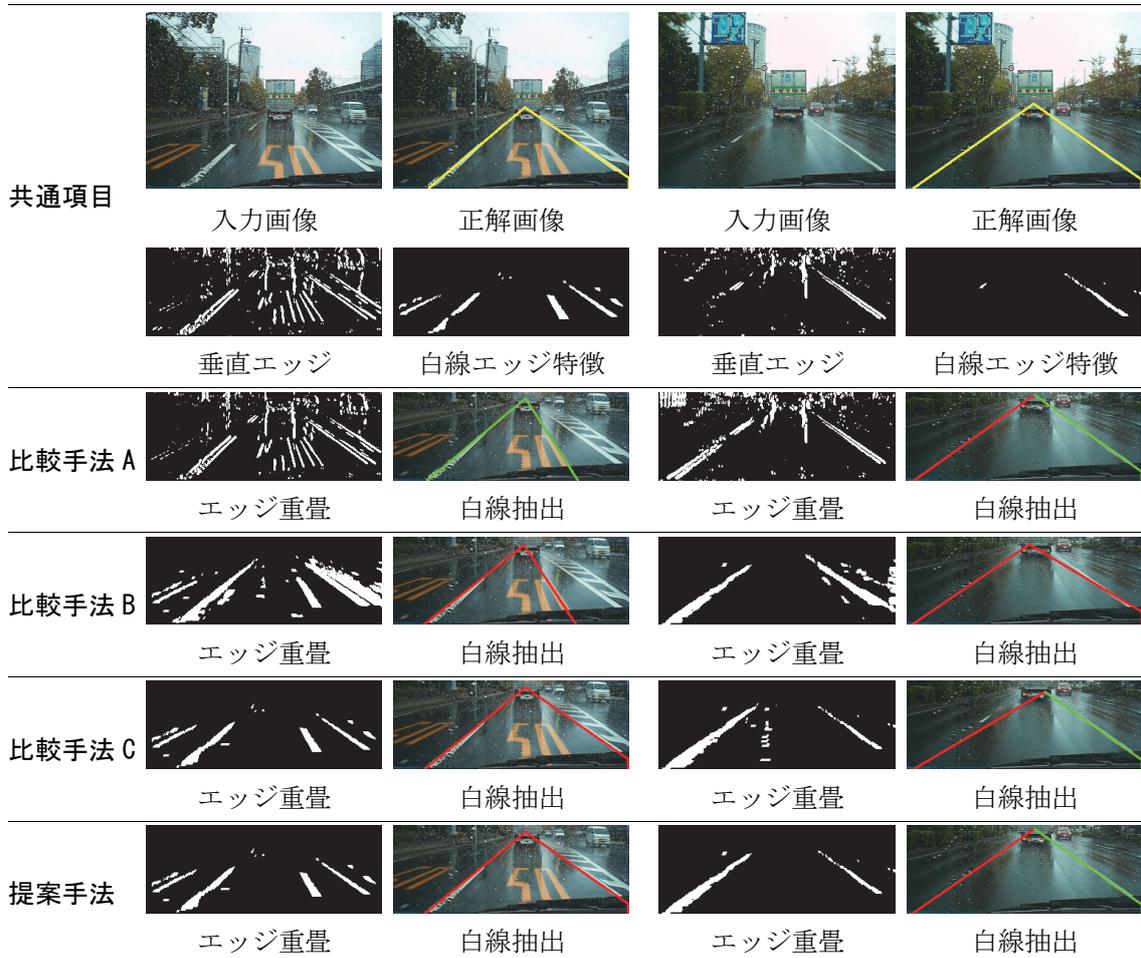
本実験シーンは, ワイパーを使用しており, かつ「速度落せ」などの特徴的なペイントが路面上に現れるものを使用した。表 2.8 より, 提案手法が左右白線の平均 x 座標誤差, 及び最大 x 座標誤差全ての項目で最小である。右白線の平均 x 座標誤差, 及び最大 x 座標誤差については比較手法 C も同様の結果であった。

図 2.36(b)で, 比較手法 B の 90 フレーム目付近において右白線に大きな誤差が生じている。なお, グラフ上では 20pixel までに表示を制限しているが, 実際の値を見ると平均誤差は 46pixel 程度にまで達した。これは, 最高速度 50km の規制標示の上を通過中のフレームであり, 図 2.35(a)に示すように, 白線エッジ特徴を考慮しても除去できなかった道路標示のエッジを重畳し, それを連結画素走査により白線として抽出したことが要因である。二段階連結画素走査を用いる比較手法 C 及び提案手法では, 雑音を重畳するものの比較手法 B に比べて小さく, 加えて現在のエッジから右白線を抽出することができたためエッジ重畳画像を参照することなく処理でき, 平均誤差 1pixel 程度で抽出できた。

さらに図 2.36(a)で, 比較手法 C の 320 フレーム目付近において左白線に大きな誤差が生じている。これは直前のフレームにおいて道路の凹凸を通過することによる振動の影響が画像に僅かながら生じているフレームであり, 図 2.35(b)に示すように極僅かではあるが, 比較手法 C における左白線のエッジ重畳画像上には古いフレームの影響が内側への突起部として現れている。これが影響して左白線が大きく右に傾き, 比較手法 C の平均誤差が 16pixel 程度まで増加したが, 重畳フレーム数を x 座標に応じて変更する比較手法 B 及び提案手法では古いエッジの影響を抑え, 0.7pixel 程度まで平均誤差を小さくすることができた。

表 2.8 一般道昼雨天シーンにおける実験結果

	比較手法 A	比較手法 B	比較手法 C	提案手法
左白線の全体平均 x 座標誤差 [pixel]	4.39	3.74	3.25	3.13
左白線の最大 x 座標誤差 [pixel]	98	28	33	21
右白線の全体平均 x 座標誤差 [pixel]	5.39	6.39	2.43	2.43
右白線の最大 x 座標誤差 [pixel]	116	83	30	30
平均処理時間 [ms]	1.69	1.01	2.05	1.88



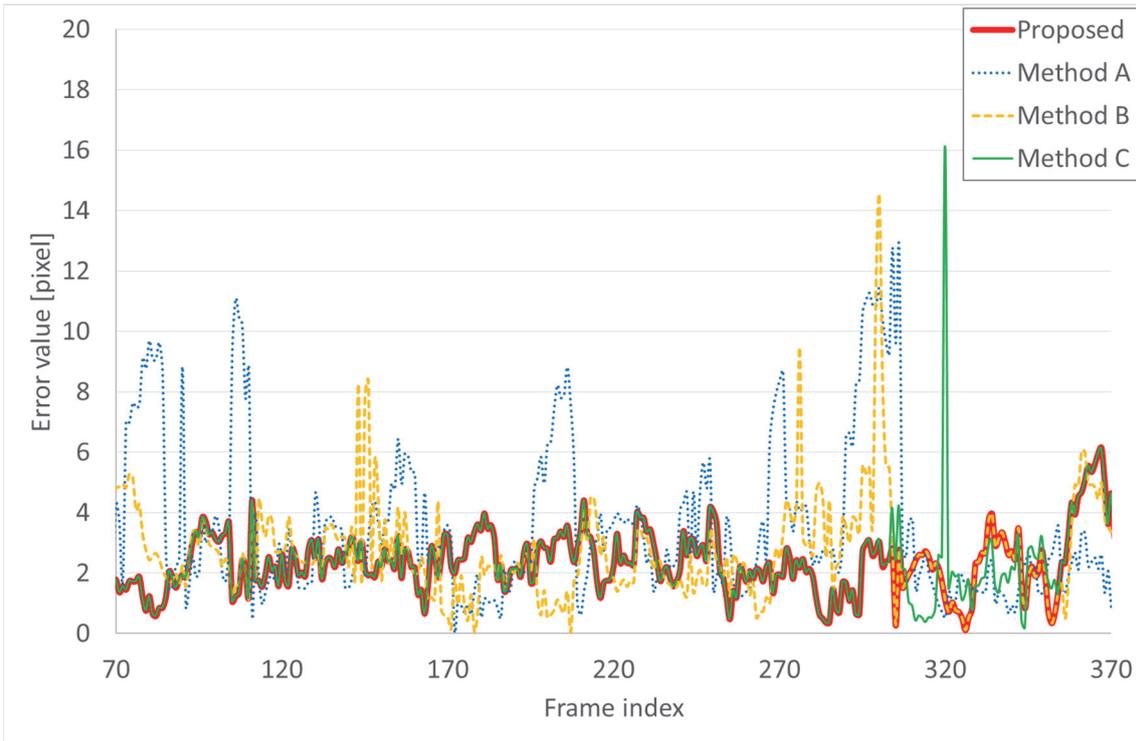
(a) 92 フレーム目の結果

(b) 320 フレーム目の結果

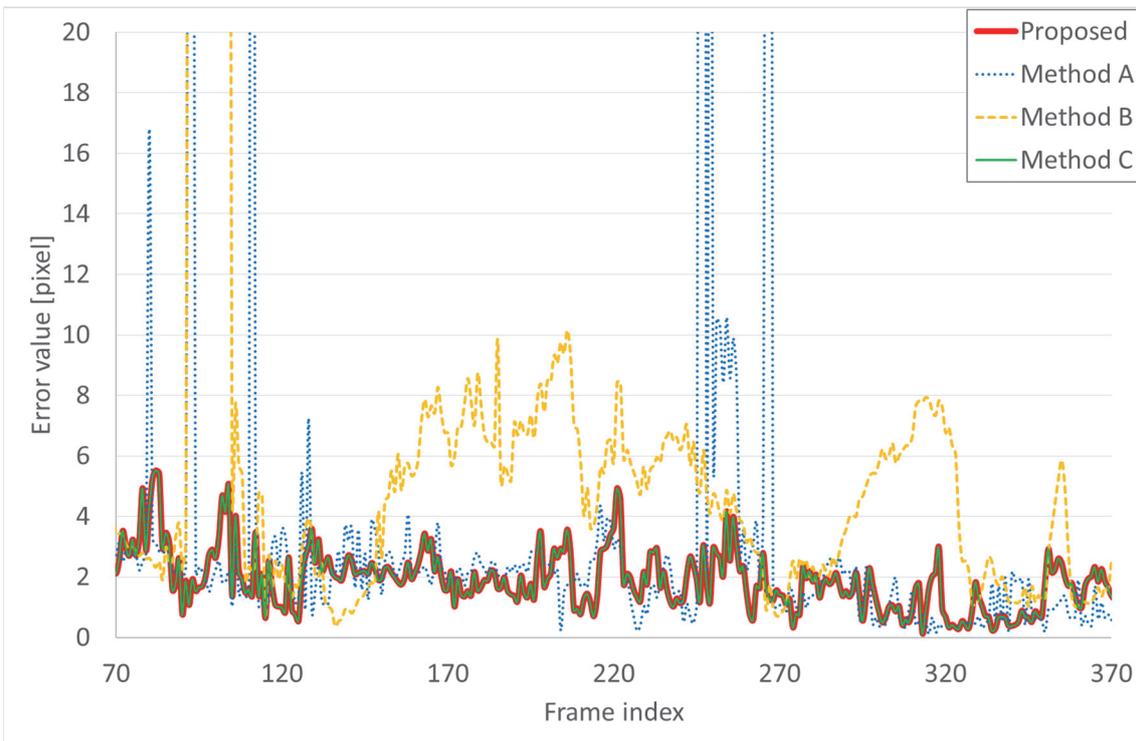
黄色線：正解白線

緑線：エッジ画像から抽出 赤線：エッジ重畳画像から抽出

図 2.35 一般道昼雨天シーンにおける白線抽出結果例



(a) 左白線



(b) 右白線：表示を Error Value 20[pixel]で制限

図 2.36 一般道昼雨天シーンにおけるフレーム毎の平均 x 座標誤差の推移

(4) 実験シーンを通した実験結果の比較と提案手法の有効性

高速道路昼晴天シーンの様に路面と白線の境界が捉えやすい場合、Sobel フィルタによるエッジ抽出を用いる比較手法 A が最も白線候補点を漏らさず抽出でき、左右白線の平均 x 座標誤差を最小とした。次点で提案手法が平均 x 座標誤差を小さくできており、その差も左右ともに約 0.6pixel に収まっている。また、最大 x 座標誤差について、左白線では提案手法と比較手法 C が 8pixel で最小となり、右白線では比較手法 A が 18pixel で最小、提案手法が次点で 21pixel となったが、その差は左白線における提案手法と比較手法の差の半分となっている。以上より、提案手法は高速道路昼晴天シーンにおいて有効な結果を示している。

一般道夜雨天シーンについて、提案手法では左白線の平均 x 座標誤差を最小にできた。右白線では、比較手法 B が 2.30pixel で最小なもの、提案手法との差は 0.01pixel であり、左白線における比較手法 B と提案手法の差は 0.09pixel であることから、わずかながら提案手法の方が優位といえる。また、最大 x 座標誤差で比較すると左右白線ともに提案手法が最小となった。以上より、提案手法は一般道夜雨天シーンにおいて有効な結果を示している。

一般道昼雨天シーンについて、提案手法では左白線の平均 x 座標誤差及び最大 x 座標誤差を最小にできた。以上より、提案手法は一般道昼雨天シーンにおいて有効な結果を示している。

参考値として、表 2.9 に、本節の実験シーンから算出した左右白線の平均 x 座標誤差を示す。表 2.9 より、提案手法は実験シーンを通して算出した際に、左右白線の平均 x 座標誤差を最小とできた。

表 2.9 実験シーンを通した実験結果

	比較手法 A	比較手法 B	比較手法 C	提案手法
左白線の全体平均 x 座標誤差 [pixel]	16.6	3.60	3.37	3.10
右白線の全体平均 x 座標誤差 [pixel]	5.39	6.39	2.43	2.43

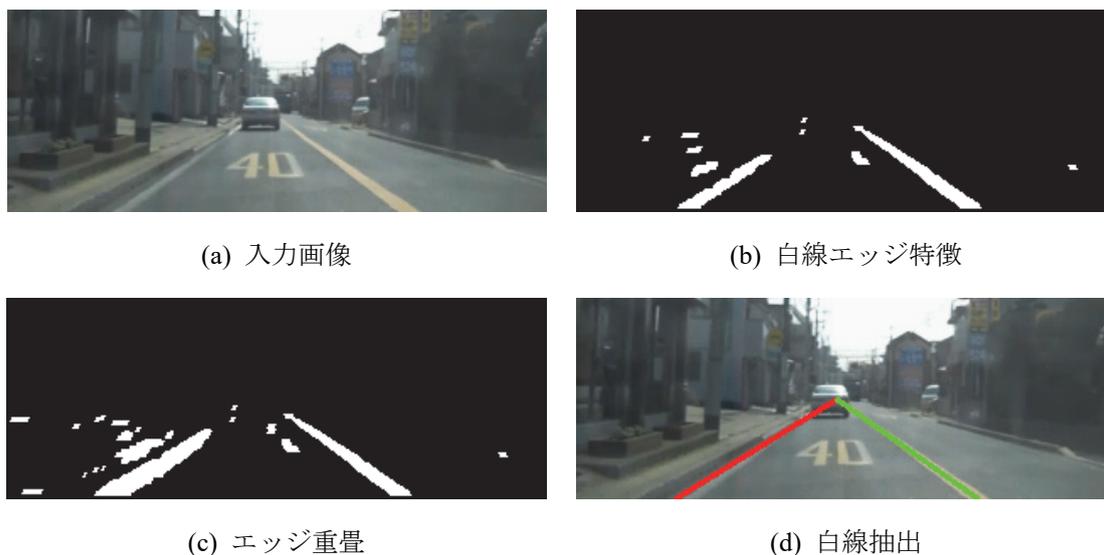
以上より、白線エッジ特徴を利用したエッジ抽出、重畳フレーム数可変なリングバッファを用いたエッジ重畳及び、二段階連結画素走査を組み合わせる提案手法は、昼夜や晴雨の環境に依らず白線抽出に有効である。

2.7 実験環境外への対応と展望

本章で提案した手法は実用上、2.6節で実験した環境外、例えば追越しのためのはみ出しを禁止する黄色線、交差点・横断歩道などへも対応できる必要がある。本節では、提案手法がそれらシーンへの適用可能かについて考察し、対応困難な場合、その展望について述べる。

(1) 黄色線の場合

黄色線は白線と同様に路面よりも輝度値が高いため、2.3.4項で述べた路面（暗）から白線（明）に向かう正のピークと白線（明）から路面（暗）に向かう負のピークという特徴がそのまま適用可能である。よって、図 2.37 に示す例のように提案手法は黄色線の影響を受けない。



緑線：エッジ画像から抽出 赤線：重畳画像から抽出

図 2.37 黄色線での白線抽出

(2) 交差点・横断歩道の場合

交差点内の場合、白線がなくなるため白線を抽出できないが、平坦な交差点直進時は交差点通過後も環境の変化は少ないため、ログを用いた白線補完により対応可能と考える。交差点右左折時も基本的にはログを用いた白線補完が適用されることになるが、先行車両が自車両よりも左あるいは右に位置する場合、先行車両検出のための処理領域限定としては機能しない。しかし本提案手法の実用上の位置づけは補助であり、ドライバーが前方を確認しない限りはそもそもの右左折が行えないため、このデメリットが与える影響は少ない。

横断歩道の場合、基本的にはエッジ方向や太さなどの点で白線と異なる特徴を持つため、図 2.38 に示すように交差点直進時と同様、白線として抽出されずログを用いた白線補完により対応できる。しかし、図 2.39 に示すように交差点の横断歩道などにおいて通過後に若干の勾配がある場合などには、一般道で確保したい処理領域である 60m 遠方を含むことができていないシーンも存在する。また、どちらの例もわずかに横断歩道のエッジを抽出しており、それが重畳されていることから、横断歩道の特徴などを定義して除外するなど、より的確に白線エッジのみを選別する手法が求められる。



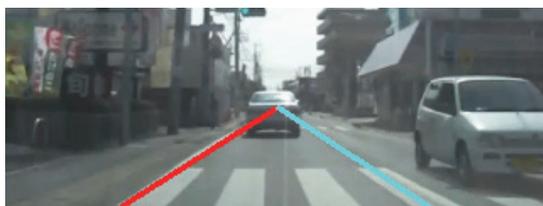
(a) 入力画像



(b) 白線エッジ特徴



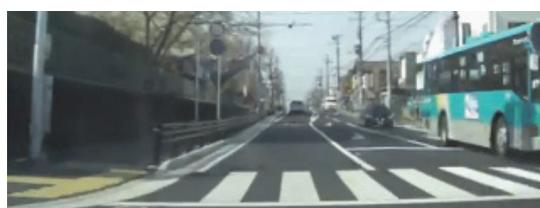
(c) エッジ重畳



(d) 白線抽出

赤線：重畳画像から抽出 青線：ログから抽出

図 2.38 横断歩道での白線抽出 1



(a) 入力画像



(b) 白線エッジ特徴



(c) エッジ重畳



(d) 白線抽出

青線：ログから抽出

図 2.39 横断歩道での白線抽出 2

(3) 勾配がある場合

勾配がある場合、白線の映り方は平坦な道と比べて変化するものの、基本的には図 2.40 や図 2.41 に示すように提案手法で対応可能である。しかし、白線の一部が先行車両で隠れたりして抽出できない場合、図 2.39 と同様にログを用いた補完では適切な処理領域を設定できないことがあるため、どの程度の勾配まで対応可能かなど、より詳細な考察が必要である。



(a) 入力画像



(b) 白線エッジ特徴



(c) エッジ重畳



(d) 白線抽出 緑線：エッジ画像から抽出
赤線：重畳画像から抽出

図 2.40 上り坂での白線抽出例



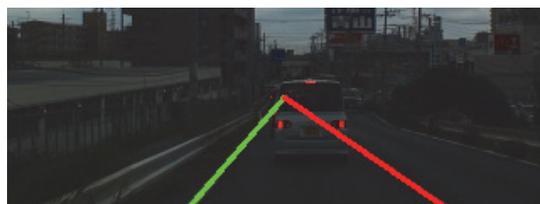
(a) 入力画像



(b) 白線エッジ特徴



(c) エッジ重畳



(d) 白線抽出 緑線：エッジ画像から抽出
赤線：重畳画像から抽出

図 2.41 下り坂での白線抽出例

(4) 白線がない場合や白線が遮蔽される場合

白線がない場合を本提案手法は対象としていないが、実用上は何らかの対応をとる必要がある。展望としては、現在の画像から白線の有無を白線エッジなどから推定し、白線がないシーンに対して標準となる処理領域を設定して対応する。この際、カメラの設置位置と関連させた標準となる処理領域の決定方法についてが残された検討課題である。

積雪により白線が遮蔽される場合についても、白線がない場合と同様に考えられ本提案手法は対象としていないが、やはり実用上は何らかの対応をとる必要がある。融雪装置が設置されていない路面においては積雪時に、図 2.42(a)に示すように雪轍が生じる。条件が合えば僅かに抽出されたエッジを重畳でき、図 2.42(d)に示すように本提案手法により処理領域を限定できることもあるが、本質的に対応できるわけではなく誤ることが大半である。そのため、白線がない場合と同様に標準処理領域の設定について検討し対応をはかる必要がある。しかし、図 2.42(c)に示すように雪轍がエッジとして抽出されることで白線の有無の推定が困難な場合も考えられるため、雪から轍、轍から雪という特徴的な路面状態を捉え、積雪の有無を推定する方法の検討などが有効と考える。

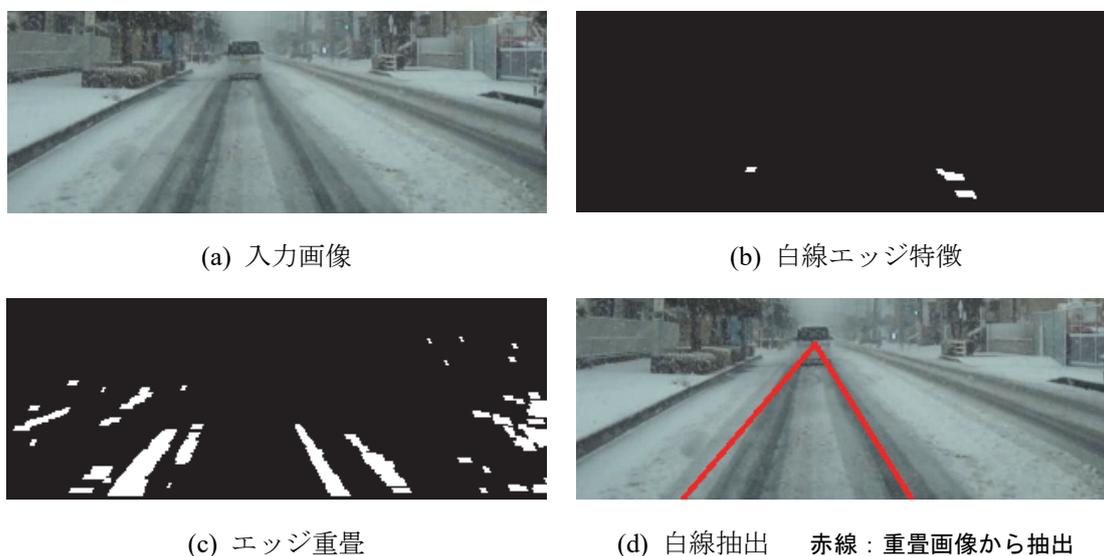


図 2.42 積雪時の白線抽出例

先行車両の接近により白線が遮蔽される場合、白線が見えなくなるため白線を抽出できないが、極めて接近した状態でない限り発生せず、自車両と先行車両が互いに停止している状態が多い。そのため環境の変化は少なく、ログを用いた白線補完により対応可能と考える。

2.8 まとめ

本章では、一般的に用いられる破線状の白線候補点やかすれた白線候補点から白線を抽出する手法に対し、破線状の白線候補点やかすれた白線候補点そのものを補完するエッジ重畳を基にした白線抽出手法を提案した。具体的には、効果的なエッジ重畳を実現するための白線エッジ特徴を利用したエッジ抽出、リングバッファを用いたエッジ重畳、及び二段階で適用する連結画素走査を組み合わせたものを提案手法として構築した。それぞれの提案を除いた手法を比較手法として3種用意し、様々な道路種別、時間帯、天候における白線抽出実験を行い、提案手法を構築するためのいずれの要素も実験環境において効果的に働くという結果を示した。

文 献

- [2-1] 堀江宏仁・小澤慎治：「連続道路画像を用いた車両前方監視」, 電気学会論文誌C, Vol.117, No.5, pp.648-657 (1997)
- [2-2] 山口直人・田森信行・塩見彰睦：「適応エッジ保存平滑化を用いた白線検出手法」, 電子情報通信学会論文誌D-II, Vol.J88-D-II, No.8, pp.1421-1431 (2005)
- [2-3] 安達栄輔・鍋島彰崇・栗田多喜夫：「車の姿勢を考慮したハフ変換による車線検出」, 電子情報通信学会技術研究報告.PRMU, Vol.105, No.615, pp.103-107 (2006)
- [2-4] 関真規人：「パーティクルフィルタとハフ変換の仮説統合による消失点の追跡」, 信学論D, Vol.J92-D, No.1, pp.131-140 (2009)
- [2-5] 大池達也：「モデルベースの認識手法による道路白線認識」, 電子情報通信学会技術研究報告.PRMU, Vol.99, No.575, pp.53-60 (2000)
- [2-6] 二宮芳樹・高橋 新・大田充彦：「高速パターン照合手法を利用したレーン認識システム」, 電子情報通信学会論文誌D-II, Vol.J86-D-II, No.5, pp.625-632 (2003)
- [2-7] 綱島宣浩・佐藤泰則・中澤和夫・中島真人：「回転型フィルタを用いた車両前方走行画像からの白線認識」, 電子情報通信学会論文誌D-II, Vol.J81-D-II, No.6, pp.1470-1473 (1998)

- [2-8] 農宋千典・小澤慎治：「高速道路走行画像からの消失点推定に基づく実時間白線検出」，
電気学会論文誌C， Vol.113， No.2， pp.139-148 (1993)
- [2-9] 関 弘翔・泉 隆・細野裕行：「白線エッジ特徴を考慮したエッジ重畳による道路
白線抽出」， 電気学会論文誌A， Vol. 137， No.1， pp.78-85 (2017)
- [2-10] 高木幹雄・下田陽久ほか：「機能編・第I部・5章 空間的情報の変換」，『新編 画像解
析ハンドブック』初版・第2刷， 東京大学出版， pp.1215-1288 (2008)
- [2-11] 高木幹雄・下田陽久ほか：「基礎編・第II部・7章 計算幾何学とモルフォロジー」，『新
編 画像解析ハンドブック』初版・第2刷， 東京大学出版， pp.829-884 (2008)
- [2-12] 栗田多喜夫：「統計的画像処理手法」，
<http://home.hiroshima-u.ac.jp/tkurita/lecture/statimage/> (2020-01)

第3章 車両下影に着目した車両識別による 先行車両検出

3.1 影に着目した先行車両検出の関連研究と本研究の位置づけ

本研究では、車内に設置した車載単眼カメラを用いて取得した車両前方画像に対して画像処理を行うことにより先行車両検出を実現する。その際、車両であることを示す画像特徴（車両特徴）の抽出が必要となる。この車両特徴として車両背面のテクスチャの対称性、エッジやテールランプなどを用いた手法が提案されている^{[3-1][3-2]}。しかし、これらの特徴は、昼夜や天候などの環境変動により対称性が崩れることや、エッジが現れなくなることなどを考慮しなければならない。また、車両の種類ごとに特徴となる位置（路面からの高さ）が固定ではないため、単眼による距離推定を行うための拘束条件を設定することが困難と考えられる。

これに対し本研究では、車両特徴として先行車両の下にできる路面上の影（車両下影）に着目する。車両下影は、低輝度でばらつきが少なく、車幅程度の大きさを持つことから遠方においても抽出が容易といった利点に加え、路面上に存在するという拘束条件があるため、距離推定が可能といった特徴がある。しかし、夜間においては特徴となりにくく、抽出は困難とされている。このことに関して夜間の先行車両付近の輝度は、自車両のヘッドライトで車両前方を照らすため、先行車両が存在する場合に、その車体は照らされて高輝度領域となる。このとき、車両下影が存在すると考えられる車体と路面の隙間は、光が車体に遮られることで周囲に比べて輝度が低くなるため、日照時よりも精度は低下するものの、夜間においても車両下影抽出は可能である^[3-3]。さらに、テールランプ抽出に基づいて車両下影抽出の処理範囲を絞り込むといった工夫により、抽出精度の向上も見込める^[3-4]。以上のことから本論文は、車載単眼カメラを利用した、車両下影に基づく先行車両抽出を検討した^[3-5]。

車両下影を車両の特徴として利用可能かについて検討した初期の取り組みとして、路面上の（国際単位系における）輝度値を計測して検討した1993年のMoriらの論文^[3-6]がある。

Mori らは、路面の一般的な影と車両下影の間で路面が乾いているか濡れているかの状態に依らず明確な輝度差が生まれるため、車両下影を車両検出の特徴として利用できる点を主張している。この Mori らの論文を基に提案された手法^{[3-7][3-8]}や、同様の考えを基にして提案されている手法などが存在する^{[3-9][3-10]}。Tzomakas ら^[3-7]は、路面上の走行可能領域をエッジ情報で区切られた領域として抽出し、路面上の輝度値が正規分布に従うと仮定したうえで標準偏差を σ としたときの 3σ に相当する値を輝度値の閾値に設定することで路面上の影領域を抽出している。さらに路面上における車両下影領域には輝度差による水平エッジが現れることを想定して、抽出した影領域との論理積演算により車両下影領域を抽出している。エッジ情報で区切られた領域として先行車両の車両下影手前までを抽出できることを想定しているため、道路標示やワイパーによりエッジ情報が変化したときに輝度値の分布が変化し期待どおりに動作しない可能性がある。Huang ら^[3-8]は、Tzomakas らと同様に水平エッジを車両下影の特徴とするものであり、車両が持つと考えられる車両左右端の垂直エッジの強度を基にペアを抽出し、抽出した垂直エッジペア内に水平エッジが存在すればそれを車両下影とし、さらに輝度値の左右対称性を組み合わせて車両を抽出する手法を提案している。Liu ら^[3-9]は、Tzomakas らの手法により輝度値の閾値 P_T を設定したうえで、画像を行ごとに走査して、 P_T 未満の輝度値かつ閾値 S_T よりも強い負の垂直エッジを左端に、 P_T 未満の輝度値かつ閾値 S_T よりも強い正の垂直エッジを右端にもつ領域を車両下影の候補領域として抽出する。その後ニアレストネイバー法によるクラスタリングを行い、車両下影候補領域を統合することで車両下影を含む車両下部領域を抽出する。最後に、教師あり機械学習手法の一つである SVM^[3-11]を用いて車両下部領域のテクスチャ特徴を学習した識別器により、抽出した領域が車両下部領域か否かの判定を行っている。Tzomakas らの手法を基にするため同様の欠点を持つほか、正のエッジ負のエッジをある閾値 S_T を基準に決定するため、建物等の影の中にある車両下影など、影の特徴が弱まった場合に未抽出となる。Nur Shazwani ら^[3-10]は、まず処理領域を大まかに路面上へ限定するために、事前にシーンごとの処理領域を設定する。そのうえでエッジを抽出し、車両下影のエッジは水平方向に連結すると考えられるため、エッジ方向とエッジ強度でエッジを絞り込むことで雑音の抽出を抑制し、車両下影らしいエッジを抽出している。また、事前に設定している処理領域との位置関係などから、車両下影として不適格なエッジを除外することで高精度化をはかっている。し

かし影の特徴，すなわちエッジが弱すぎることによる未検出や，道路標示や標識などの物体を誤検出することなどが課題として残っている。

基本的に影の特徴表現として低輝度の水平エッジに着目するという手法が多いが，低輝度を評価するために輝度値に閾値を設定しており，その設定方法として単純に水平エッジで区切られた領域内の輝度分布を用いているため道路標示などを多く含む環境やワイパーに弱い。あるいは事前に設定した処理領域内で水平エッジ抽出する手法もあるが，シーンごとに設定する方法では実用性に欠け，また車両下影の特徴が弱まった時に未抽出となることからエッジの閾値設定方法も課題として残っている。よって，道路標示等の影響を抑制した白線抽出などの手法により処理領域を限定することがより望ましく，車両下影の特徴が弱まった際でも抽出できるように事前に閾値の設定を必要としない手法であることが望ましい。また，車両下影のみをもって車両とするのは信頼性に欠けるといえ，車両下部領域のテクスチャを SVM により学習して車両か否かを識別する手法もあるが，車両としての特徴に乏しい領域であることに加え，下部領域を車両下影候補領域の統合とクラスタリングにより求めるためパターンが膨大となる問題もある。

本論文では，関連研究同様に低輝度や水平エッジを持つという特徴に基づき影を抽出するが，第 2 章で提案した手法により抽出する白線を用いることで高速かつ高精度に処理領域を限定する。この領域内の統計量や局所的な特徴に着目して車両下影を抽出することで，事前に設定する条件を最低限にしつつ様々なシーンへの対応をはかる。さらに白線抽出により求めた消失点から車両下影候補までの距離を基に車両全体を含む車両スケールを推定したうえで，車両下影候補の上部領域に対して機械学習により車両背面の特徴を学習し構築する車両識別器（車両・非車両の識別を行う識別器）を適用し，車両の有無を識別する 2 段階の検出とする。これにより，車両としての信頼性を担保した先行車両検出を検討する。車両識別のみで先行車両検出を行うのではなく，車両下影抽出と併用する理由は，単眼視による車間距離推定には，車両下影の持つ特徴が不可欠なためである。これに加え，画像全体を走査する場合と比較して高速かつ高精度に車両識別が可能という点も挙げられる。

3.2 車両下影に着目した車両識別による先行車両検出の概要

図 3.1 に、本論文で提案する車両下影に着目した車両識別による先行車両検出の流れを示す。

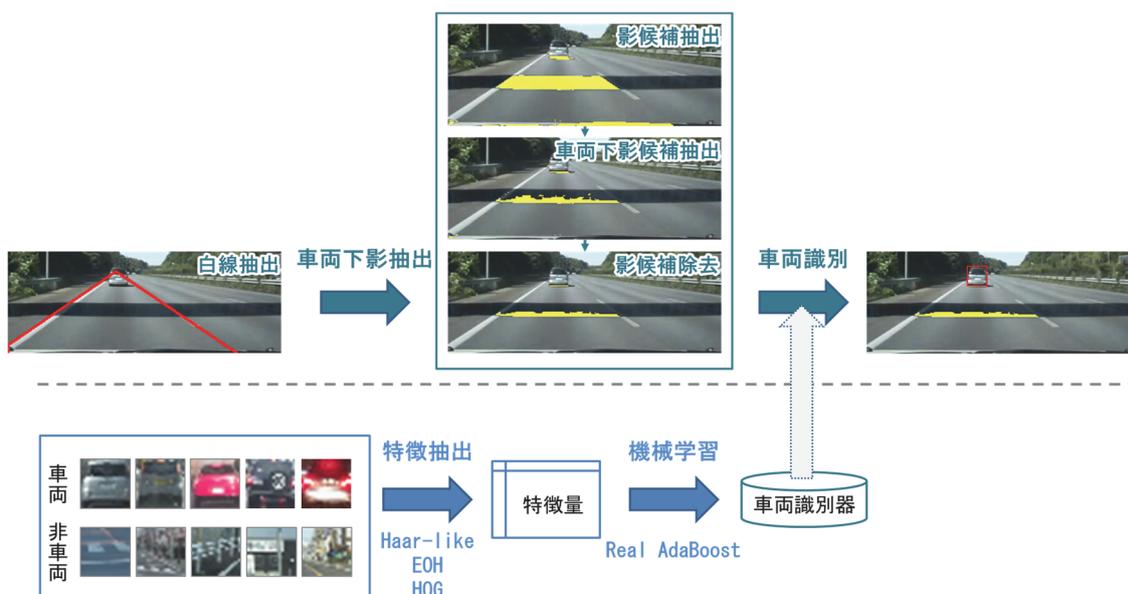


図 3.1 車両下影に着目した車両識別による先行車両検出の流れ

本論文では車両下影の利点から、第 2 章の手法により抽出する白線内に限定した処理領域において車両下影に基づいた先行車両検出を行う。車両下影抽出は、「影候補抽出」「車両下影候補抽出」「影候補除去」の 3 つから構成する。車両下影のみでは車両としての信頼性が低いため、車両下影の上には車両が存在するという考えのもと、車両下影の上部領域が車両か非車両かを識別する車両識別を行う。車両識別は車両画像と非車両画像から Haar-like 特徴量^[3-12]などの画像局所特徴量を抽出し、Real AdaBoost^[3-13]を用いたオフライン機械学習により特徴を学習して構築する車両識別器を用いて行う。

3.3 車両下影抽出

車両下影抽出には、車両下影の持つ輝度が低くばらつきも少ないという特徴と、車幅程度の大きさを持ち横に広がって存在するという特徴を利用する。本論文の車両下影抽出は「影候補抽出」「車両下影候補抽出」「影候補除去」から構成する。

3.3.1 影候補抽出

抽出対象である車両下影は輝度が非常に低いため、基本方針として車両前方画像に対して輝度情報を用いた2値化を行うことにより影候補を抽出する。ここで、車両下影抽出の処理領域内には車両下影以外にも輝度の低い箇所が存在することがある。したがって全てのフレームに対して固定閾値で2値化を行うと影候補が正しく抽出できないため、閾値はフレーム毎に動的に決める必要がある。このとき雑音を抑えて車両下影を抽出するためには、処理領域内においてP-タイル法のように一定割合の低輝度画素を抽出する方法等があるが、その割合は推定困難なパラメータとなり、車両下影よりも低輝度の画素が一定割合以上存在した場合に車両下影を抽出できない。そこで、処理領域内の平均輝度値を利用し、まず確実に車両下影を含む影候補としての抽出を検討する。処理領域内において影領域が一部しかない場合、車両下影は平均輝度値よりも必ず低輝度領域になり、また処理領域内が全体的に影で覆われている場合でも、車両で遮られた車両下影領域は平均輝度値よりも低輝度領域となることが期待できる。処理領域内の平均輝度値をそのまま用いて二値化を行うと雑音の割合が大きくなりすぎるため、本論文では平均輝度の85%として、0.85倍した値で二値化を行う。図3.2に影候補抽出の例を示す。



(a) 原画像



(b) 処理画像

図 3.2 影候補抽出の画像例

3.3.2 車両下影候補抽出

影候補抽出では、影領域を抽出できているが車両下影領域としては雑音が多く残る。ここで、3.1節で述べたように関連研究においては基本的に低輝度の水平エッジを車両下影の特徴としてきた。そこで本論文では、輝度値に加えてエッジを含むテクスチャ特徴を利用して影候補から車両下影候補を抽出する。テクスチャ特徴には CLBP (Compound Local Binary Pattern) 特徴量^[3-14]を利用する。CLBP 特徴量とは、画像のテクスチャを表現する特徴としてよく用いられる LBP (Local Binary Pattern) 特徴量^[3-15]を改良したものである。LBP 特徴量とは画像のテクスチャを表現する特徴であり、照明変動に頑健な性質を持つ。LBP 特徴量 \mathbf{l} の算出は、半径 R の円とその円上に位置する K 個の近傍画素を定義し、 K 個それぞれの画素値 $L(k)$ と円の中心である着目画素値 $L(c)$ を用いて式(3.1)により行う。

$$\mathbf{l} = \sum_{k=0}^{K-1} [s(L(k), L(c)) \ll k] \quad (3.1)$$

$$s(L(k), L(c)) = \begin{cases} 1 & L(k) > L(c) \\ 0 & otherwise \end{cases}$$

式中の \ll は左ビットシフトを意味し、 \mathbf{l} はビット列とする。

LBP 特徴量は近傍画素との輝度差のみで符号化するのに対し、CLBP 特徴量は近傍画素との平均輝度差も考慮して符号化するため、より照明変動に頑健な性質を持つ。CLBP 特徴量 \mathbf{c} の算出は、半径 R の円とその円上に位置する K 個の近傍画素の画素値 $L(k)$ と円の中心である着目画素値 $L(c)$ を用いて式(3.2)により行う。

$$\mathbf{c} = \sum_{k=0}^{K-1} [(s(L(k), L(c)))_2 \ll 2k] \quad (3.2)$$

$$s(L(k), L(c)) = \begin{cases} 00 & L(k) - L(c) < 0, |L(k) - L(c)| \leq K_{\text{avg}} \\ 01 & L(k) - L(c) < 0, |L(k) - L(c)| > K_{\text{avg}} \\ 10 & L(k) - L(c) \geq 0, |L(k) - L(c)| \leq K_{\text{avg}} \\ 11 & otherwise \end{cases}$$

式中の $()_2$ は 2 進数を、 \ll は左ビットシフトを意味し、 \mathbf{c} はビット列とする。また、式中の K_{avg} は、近傍における $L(k)$, $L(c)$ 間の差の平均値である。

本論文では、着目画素の周囲 8 近傍 ($R = 1, K = 8$) を利用した CLBP 特徴量を基にする。理想的には、車両下影とそうでない路面や影領域には周囲の平均よりも大きな輝度差が生じる。また、横に広がって存在する車両下影の特徴から、考慮するのは水平エッジを算出するときと同様に上方 3 近傍及び下方 3 近傍とすることが有効である。ここで車間距離推定への応用を前提とすると、安全のためにはより自車両に近い車両下影下端の位置を捉えられるのが望ましい。そのため、上方 3 近傍が着目画素よりも暗く、かつその輝度差が周囲平均よりも大きい画素（上方 3 近傍の CLBP 特徴量の符号が全て 01 となる画素）、あるいは下方 3 近傍が着目画素よりも明るく、かつその輝度差が周囲平均よりも大きい画素（下方 3 近傍の CLBP 特徴量の符号が全て 11 となる画素）を車両下影候補として影候補から抽出する。図 3.3 に車両下影候補抽出の画像例を示す。

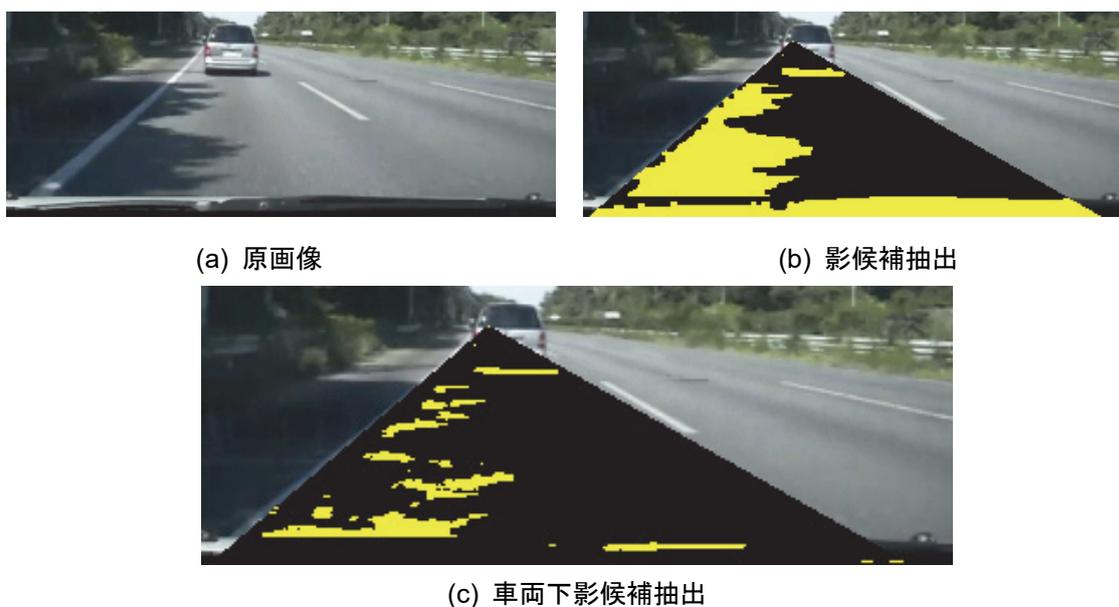


図 3.3 車両下影候補抽出の画像例

3.3.3 影候補除去

CLBP 特徴量により車両下影候補の抽出を行った図 3.3(c)のままでは、図 3.3(b)に示す影候補抽出よりは減少するものの、車両下影以外の雑音も多く残っている。そこで、横に広がって存在するという車両下影の特徴から、1 行ずつ影候補画素のカウントを行い、カウントが規定数以上となれば車両下影候補画素を残し、規定数未満となれば影候補であるが車両下影候補ではないとして除去する、影候補除去を行う。

図 3.4 に影候補除去の概念図を示す。また図 3.5 に、実際に影候補除去を行った画像例を示す。

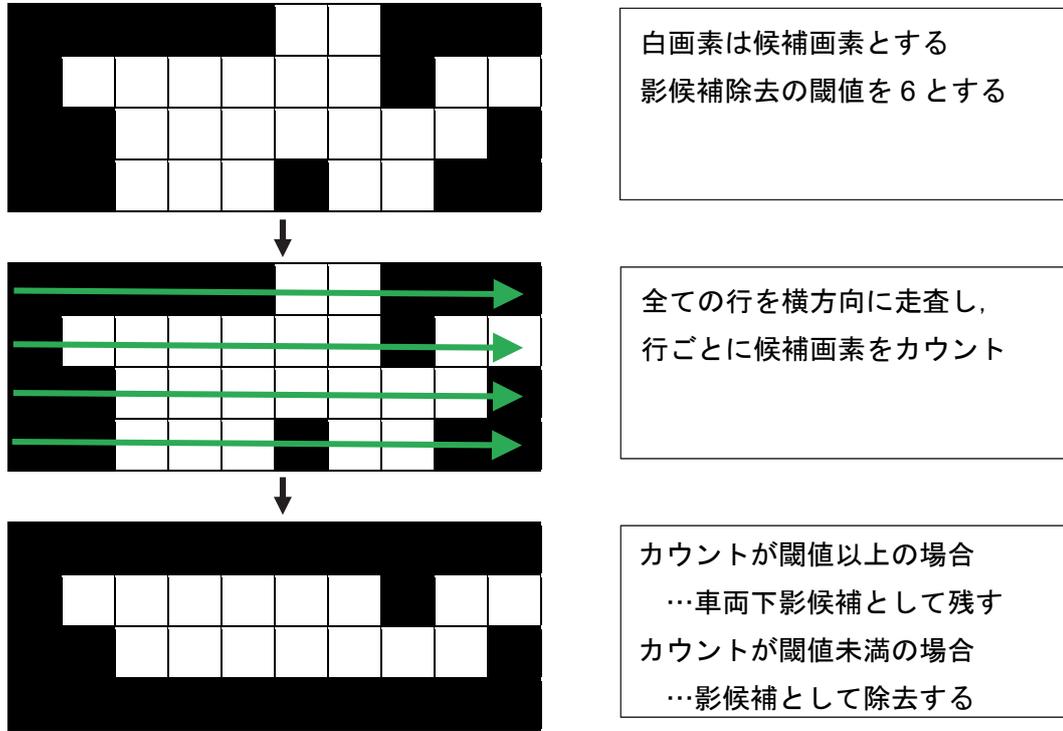
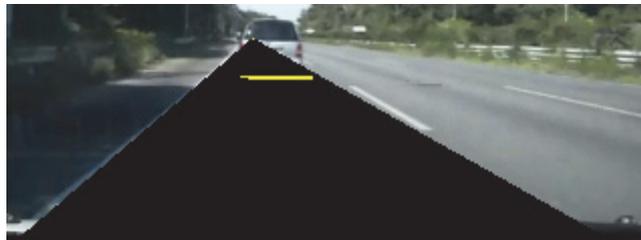


図 3.4 影候補除去の概念図



(a) 原画像

(b) 車両下影候補抽出



(c) 影候補除去

図 3.5 影候補除去の画像例

3.4 車両識別

3.3 節で述べた車両下影抽出は雑音成分の除去が十分でないため、建物などの影を車両下影に誤ることや、車両下影が複数抽出される問題（車両下影の誤抽出）が生じる（図 3.6）。そのため、先行車両検出としての信頼性を向上させるためには、正しい車両下影の選別が必要となる。

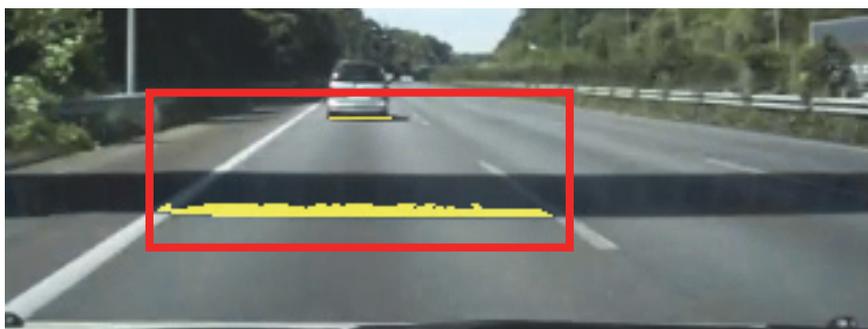


図 3.6 車両下影抽出の問題点

この問題に対し、車両下影の上部領域には必ず車両が存在することから、本論文では抽出された車両下影の上部領域が車両か非車両かを識別することで正しい車両下影を選別する、「車両識別」を行う。

本論文の車両識別は、車両の識別に有効な画像の特徴量を統計的教師あり機械学習の一つである Boosting^[3-16]により選択的に学習して構築する車両識別器を用いて行う。

3.4.1 Boosting による車両識別器の構築

Boosting とは、与えられた正解・不正解の学習サンプルをもとに、ランダムに選択するよりは良い程度の性能を持つ弱い識別器（弱識別器：weak classifier）を逐次的に学習し、それらを組み合わせることで最終的に精度の高い識別器（強識別器：strong classifier）を構築する学習アルゴリズムである。最初期に実用的な Boosting アルゴリズムを実現したものとして AdaBoost (Adaptive Boosting)^[3-16]が提案された。AdaBoost とは、識別を誤った学習サンプルの重みを大きく、識別できた学習サンプルの重みを小さく、適応的 (adaptive) に更新しながら複数の弱識別器を学習することで、高精度な強識別器を構築するアルゴリズムである。 t 個目の弱識別器 $h_t(x)$ の信頼度 α_t (重み) として T 個学習した場合、強識別器 $H(x)$ は式(3.3)に示す線形結合で構築できる。

$$H(x) = \text{sign} \left[\sum_{t=1}^T \alpha_t h_t(x) - \lambda \right] \quad (3.3)$$

式中の λ は閾値を表し、関数 $\text{sign}[\beta]$ は、 β が正であれば正解（車両）であることを示す+1、負であれば不正解（非車両）であることを示す-1を返す関数である。学習時には $\lambda = 0$ を用いる。

それぞれの弱識別器は、入力パターン x に対しそのパターンが属すると判定したクラスラベル {正解 : +1, 不正解 : -1} を出力する。強識別器の出力は弱識別器の信頼度を重みとした加重和になり、AdaBoost の学習は弱識別器 $h_t(x)$ と信頼度 α_t の決定を繰り返すことによる強識別器 $H(x)$ の構築が目的となる。弱識別器は $h_1(x)$ から逐次的に学習するが、識別の正誤を利用した適応的な学習サンプル重みの更新により、後段で学習される弱識別器はその1つ前の弱識別器が苦手とするパターンの識別に有効なものを学習できる。例えば、弱識別器 $h_2(x)$ は弱識別器 $h_1(x)$ が苦手とするパターンに対して有効な識別能力を持つ。

さらに先述の AdaBoost を拡張した手法として Real AdaBoost^[3-13]と呼ばれる Boosting アルゴリズムが提案されている。Real AdaBoost とは、AdaBoost における弱識別器の2値出力を、特徴量の確率密度分布に応じて実数値 (real) 化したものである。特徴量の確率密度分布 W は、特徴量の値をある区間 (ビン) ごとに区切り、それぞれのビンに学習サンプル重みを累積することで作成する。特徴量の確率密度分布を用いることで、AdaBoost よりも効果的なサンプル重み更新が行えることから学習の収束が早く、AdaBoost により構築した車両識別器よりも高速な識別が可能といわれている。高速かつ高精度な識別が期待できる点から、本論文では車両識別器の構築に Real AdaBoost を採用する。

Real AdaBoost における弱識別器の評価は、正解・不正解サンプルの確率密度分布がどれだけ分離できているかという点に着目して行う。分離度の評価には Bhattacharyya 係数^[3-17]が用いられる。また、Real AdaBoost では弱識別器を特徴量の確率密度分布に基づいて構築するため、極端に低い生起確率を持つ特徴量が現れた場合、学習に大きな影響を及ぼす。これを解決するために、Real AdaBoost の弱識別器に飽和関数を導入することが提案されており^[3-18]、本論文では弱識別器の出力に飽和関数の一種、双曲線正接関数 (hyperbolic tangent) を採用する。

表 3.1 に Real AdaBoost のアルゴリズムを示す。

表 3.1 Real AdaBoost のアルゴリズム

Step1:	前処理 学習サンプル $\mathbf{S} = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$ x_n : サンプル, y_n : 属性 { 正解(+1), 不正解(-1) }
Step2:	学習サンプルの重み $D_{t=1}(n)$ の初期化 $D_1(n) = 1/N$ for all $n = 1, \dots, N$
Step3:	For $t = 1, 2, \dots, T$ T 個の弱識別器の学習
Step3-a:	For $m = 1, 2, \dots, M$ M 個の弱識別器候補の生成
Step3-b:	弱識別器候補 $h_{t,m}(x)$ の確率密度分布 $W_{t,m}$ の作成 $W_{t,m+}^j = \sum_{n:j \in J \cap y_i=1} D_t(n), W_{t,m-}^j = \sum_{n:j \in J \cap y_i=-1} D_t(n)$
Step3-c:	確率密度分布 $W_{t,m}$ の類似度 $z_{t,m}$ の算出 $z_{t,m} = 2 \sum_j \sqrt{W_{t,m+}^j \cdot W_{t,m-}^j}$
Step3-d:	弱識別器 $h_t(x)$ の学習 $h_t(x) = \arg \min z_{t,m}$ ただし, 弱識別器 $h_t(x)$ の出力 $h_t(x) = \begin{cases} 0 & \text{if } W_{t+}^j = W_{t-}^j = 0 \\ \frac{W_{t+}^j - W_{t-}^j}{W_{t+}^j + W_{t-}^j} & \text{otherwise} \end{cases}$
Step3-e:	学習サンプルの重み更新 $D_{t+1}(n) = D_t(n) \exp\{-h_t(x_n)y_n\}$
Step3-f:	学習サンプルの重み正規化 $D_{t+1}(n) \leftarrow \frac{D_{t+1}(n)}{\sum_{i=1}^N D_{t+1}(i)}$
Step4:	強識別器 $H(x)$ の構築 $H(x) = \text{sign} \left[\sum_{t=1}^T h_t(x) - \lambda \right] \quad (\lambda \text{は閾値})$

以降では, 各ステップについて述べる。

Step1 : 前処理

(1) 概要

N 枚の学習サンプル $\mathcal{S}=\{(x_1,y_1), (x_2,y_2), \dots, (x_n,y_n), \dots, (x_N,y_N)\}$ を用意する。ただし, x_n は学習サンプル (画像), y_n はクラスラベル {正解: +1, 不正解: -1} とする。本論文において識別の対象となる物体は車両であるため, 正解の車両画像と不正解の非車両画像が必要となる。この学習サンプルは車両前方画像から手作業で切り出し, 20×20 pixel に正規化して用いる。また, クラスラベル y_n は {車両: +1, 非車両: -1} とした。図 3.7 に本論文で使用した学習サンプルの画像例を示す。なお, 20×20 pixel という画像サイズは, VGA サイズの車両前方画像上で自車両からおよそ 100m 遠方に先行車両が位置するときのサイズに相当する。



図 3.7 学習サンプルの画像例

(2) 本論文での工夫点

学習サンプルの量や多様性が最終的な車両検出性能に強く影響するが, 様々な多様性を含んだ学習サンプルを用意するためには膨大な作業コストが必要となる。そこで本論文では輝度調整や, コントラスト調整によりデータ拡張 (data augmentation) を行い学習サンプルに多様性を与えた。図 3.8 に本論文で施したデータ拡張の例を示す。

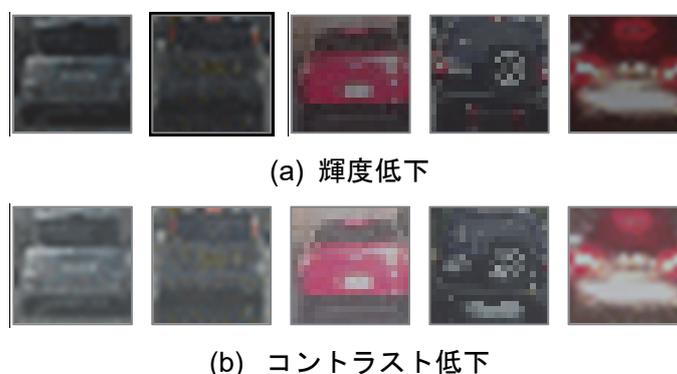


図 3.8 データ拡張の例

Step2 : 初期化

N 枚の学習サンプルがあるとき、初回学習時の重み $D_1(n)$ を式(3.4)により均等に割り振る。ここで、添え字の“1”は初回の学習であることを表し、 n は何枚目の学習サンプルであるかを表す。

$$D_1(n) = \frac{1}{N} \quad (3.4)$$

Step3 : T 個の弱識別器の学習

(1) 概要

用意した学習サンプルに対して、任意の学習回数あるいは任意の識別率を達成するまで弱識別器 $h_t(x)$ の学習 (Step3-a~f) を繰り返すことで、最終的に T 個の弱識別器を学習する。既に述べたとおり、Real AdaBoost における弱識別器 $h_t(x)$ の出力は特徴量の確率密度分布に応じた実数値である。式(3.5)に算出式を示す。

$$h_t(x) = \frac{1}{2} \ln \frac{W_{t+}^j}{W_{t-}^j} \quad (3.5)$$

確率密度分布 W は、特徴量の値をある区間 (ビン) ごとに区切り、それぞれのビンに学習サンプル重みを累積することで作成する。図 3.9 に確率密度分布の例を示す。

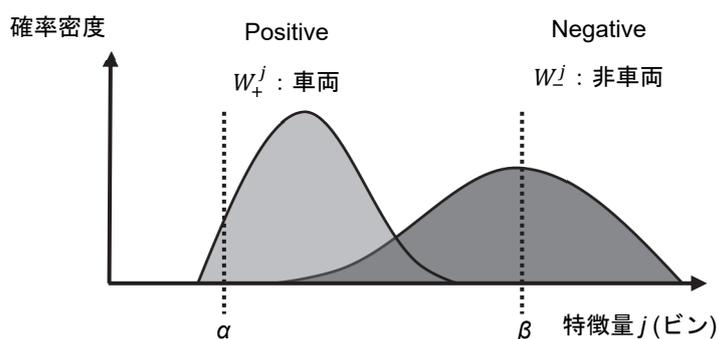


図 3.9 確率密度分布の例

ここで、 W_+^j は正解サンプルを用いて作成した確率密度分布を、 W_-^j は不正解サンプルを用いて作成した確率密度分布を表す。 j はサンプル x に対して計算した特徴量が属する確率密度分布のビンを指す。例えば、サンプル x が図 3.9 中の α で示すビンに属する場合、式(3.5)に

より計算すると分子 W_{t+}^j のほうが分母 W_{t-}^j よりも大きいため正の実数値となる。一方、サンプル x が図 3.9 中の β で示すビンに属する場合、式(3.5)により計算すると分子 W_{t+}^j のほうが分母 W_{t-}^j よりも小さいため負の実数値となる。すなわち、弱識別器 $h_t(x)$ の出力の正負によって正解・不正解どちらのクラスに属すると識別したかを表現でき、その値が識別の信頼度を表現できる。

Step3-a : M 個の弱識別器候補の生成

本論文においては、学習サンプル画像に合わせた 20×20 pixel の窓の中で、用いる画像特徴量の種類・位置・スケールを網羅的に変化させたものを M 個の弱識別器候補として生成する。AdaBoost と異なり Real AdaBoost では閾値を設定する必要がないため、学習効率は飛躍的に向上する。

Step3-b : 弱識別器候補 $h_{t,m}(x)$ の確率密度分布 $W_{t,m}$ 作成

m 番目の弱識別器候補 $h_{t,m}$ により算出した特徴量を確率密度分布ビンに変換し、学習サンプルの重みを足し合わせることで確率密度分布を作成する (式(3.6)及び式(3.7))。

$$W_{t,m+}^j = \sum_{n:j \in J \cap y_i=1} D_t(n) \quad (3.6)$$

$$W_{t,m-}^j = \sum_{n:j \in J \cap y_i=-1} D_t(n) \quad (3.7)$$

Step3-c : 確率密度分布 $W_{t,m}$ の類似度 $z_{t,m}$ 算出

弱識別器候補 $h_{t,m}(x)$ に対する 2 つの確率密度分布 $W_{t,m+}^j$ 及び $W_{t,m-}^j$ の類似度を Bhattacharyya 係数により算出する。Bhattacharyya 係数は 0~1 で表され、1 のときに 2 つの分布の完全一致を示す。すなわち、Bhattacharyya 係数の値が小さいほど 2 つの分布が分離していることを意味する。弱識別器候補 $h_{t,m}(x)$ における確率密度分布の類似度 $z_{t,m}$ を、値域を拡げるために Bhattacharyya 係数を倍にした式(3.8)により算出する。

$$z_{t,m} = 2 \sum_j \sqrt{W_{t,m+}^j \cdot W_{t,m-}^j} \quad (3.8)$$

Step3-d : 弱識別器 $h_t(x)$ の学習

式(3.9)により、類似度 $z_{t,m}$ が最小となる弱識別器候補 $h_{t,m}(x)$ を、現在の学習ラウンド t における弱識別器 $h_t(x)$ として採用する。弱識別器候補 $h_{t,m}(x)$ に対する2つの確率密度分布 $W_{t,m+}^j$ 及び $W_{t,m-}^j$ は、正解サンプル及び不正解サンプルの分布であるため、2つの分布の類似度が小さい、すなわち分離しているほど識別に有効な特徴量である。

$$h_t(x) = \operatorname{argmax}_{z_{t,m}} \quad (3.9)$$

Step3-e : 学習サンプルの重みの更新

弱識別器 $h_t(x)$ の実数出力値をもとに、全ての学習サンプルの重みを式(3.10)により更新する。この式は、採用した弱識別器 $h_t(x)$ が識別を誤った学習サンプルの重みを大きく、正解した学習サンプルの重みを小さく算出できる。この適応的重み更新により、次のラウンドでは、現在のラウンドで選択された弱識別器の欠点を補うような弱識別器が選択されることになる。AdaBoostの場合、更新における重み変化量は弱識別器の信頼度に基づくため、サンプル毎の変化量は一定となる。それに対しReal AdaBoostでは、重み変化が弱識別器の出力に基づいており、その出力がサンプル毎に異なるため、より難しい学習サンプルの重みをより大きくといった、効果的な重み更新が実現できる。

$$D_{t+1}(n) = D_t(n) \exp(-h_t(x_n)y_n) \quad (3.10)$$

Step3-f : 学習サンプルの重みの正規化

更新された学習サンプルの重みの総和が1になるように式(3.11)により正規化する。

$$D_{t+1}(n) \leftarrow \frac{D_{t+1}(n)}{\sum_{i=1}^N D_{t+1}(i)} \quad (3.11)$$

(2) 本論文での工夫点

図3.9中の α や β で示すビンのように $W_{t-}^j \cong 0$ や $W_{t+}^j \cong 0$ となる極端な分布の場合、式(3.5)より算出する弱識別器 $h_t(x)$ の出力が正または負の無限大に発散する。Real AdaBoostにおいてサンプル x の重みは弱識別器 $h_t(x)$ を基に更新するため、これらのサンプルは重みが限りなくゼロとなり以後の学習に悪影響を及ぼす。これを防ぐために弱識別器 $h_t(x)$ の出力に飽和関数を適用することが提案されている^[3-18]。飽和関数としては式(3.12)に示す双曲線正接関数が採用されている。

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.12)$$

双曲線正接関数を導入した場合の弱識別器 $h_t(x)$ の出力は式(3.13)のようになり、識別の信頼度を[-1,1]で表現できる。

$$h_t(x) = \tanh\left(\frac{1}{2} \ln \frac{W_{t+}^j}{W_{t-}^j}\right) = \frac{W_{t+}^j - W_{t-}^j}{W_{t+}^j + W_{t-}^j} \quad (3.13)$$

ただし式(3.13)においても、 W_{t+}^j 及び W_{t-}^j の両方がゼロとなる場合、分母がゼロとなり計算できないため、本論文ではその場合の出力をゼロと定義した式(3.14)を弱識別器 $h_t(x)$ に用いる。

$$h_t(x) = \begin{cases} 0 & \text{if } W_{t+}^j = W_{t-}^j = 0 \\ \frac{W_{t+}^j - W_{t-}^j}{W_{t+}^j + W_{t-}^j} & \text{otherwise} \end{cases} \quad (3.14)$$

Step4 : 強識別器 $H(x)$ の構築

学習した T 個の弱識別器の足し合わせにより強識別器 $H(x)$ を構築する。強識別器 $H(x)$ は式(3.15)で表される。AdaBoost との大きな違いは、Real AdaBoost で設計する弱識別器の出力が AdaBoost における信頼度の意味合いも兼ねることができるため、弱識別器 $h_t(x)$ の信頼度 α_t が必要ない点にある。

$$H(x) = \text{sign} \left[\sum_{t=1}^T h_t(x) - \lambda \right] \quad (3.15)$$

式中の λ は閾値を表し、関数 $\text{sign}[\gamma]$ は、 γ が正であれば正解（車両）であることを示す+1、負であれば不正解（非車両）であることを示す-1を返す関数である。学習時には $\lambda = 0$ を用いる。

3.4.2 車両識別のための画像特徴量

Real AdaBoost における弱識別器と特徴量は 1 対 1 対応するため、弱識別器の学習は識別に有効な特徴量の選択にほかならない。

本論文の車両識別は、先行車両の検出が比較的容易である日中や晴天といった環境だけに限らず、先行車両の検出が困難な夜間や雨天などのあらゆる環境においても対応できる必要がある。夜間や雨天といった環境の変化に伴って生じる画像上の変化として、照明変動の影響による全体的な輝度変化や、建物などの影や雨滴などによる部分的な輝度変化及び遮蔽が考えられる。そのため本論文では、前述のような画像の変動要素に対して頑健である局所特徴量を車両識別のための特徴量として用いる。

局所特徴量とは対象物体の局所的な画像特徴に着目して情報を抽出する特徴量であり、画像に生じる環境変化の影響や物体の形状変化に対して頑健な特徴量である。局所特徴量には、対象の輝度情報に着目したものやエッジ情報に着目したものが存在する。輝度に着目する特徴量としては Haar-like 特徴量^{[3-12][3-19][3-20]}があり、エッジに着目する特徴量としては EOH 特徴量^[3-21]や HOG 特徴量^[3-22]などがある。以下の 3.4.3 項～3.4.4 項でそれぞれについて述べる。

3.4.3 Haar-like 特徴量

Haar-like 特徴量は白と黒 2 つの矩形領域を組み合わせた形状で表され、式(3.16)に示すように白(r_1)と黒(r_2)の矩形領域の輝度値の合計である $Y_{\text{sum}}(r_1)$ 及び $Y_{\text{sum}}(r_2)$ の差を特徴量 F とするものである^[3-12]。

$$F(r_1, r_2) = Y_{\text{sum}}(r_1) - Y_{\text{sum}}(r_2) \quad (3.16)$$

矩形領域の合計を利用する場合は領域の大きさによって値域が異なるため、本論文においては輝度平均値 $Y_{\text{ave}}(r_1)$, $Y_{\text{ave}}(r_2)$ の差を式(3.17)により算出し、特徴量 F とする。

$$F(r_1, r_2) = Y_{\text{ave}}(r_1) - Y_{\text{ave}}(r_2) \quad (3.17)$$

Haar-like 特徴量の形状は、これまでに様々なものが提案され用いられている。本論文では、文献[3-19]を参考に図 3.10 に示す 9 種の形状を用いる。Edge features は車体と路面の輝度差や車体とリアガラスの輝度差などを捉えるのに有効と考えた。Line features は Edge features を拡張し、背景、車体、背景や路面、車体、リアガラスなどの全体的な輝度差を捉えるのに有効と考えた。また Center-surround feature はリアガラスと車体を含むその周囲や車両全体と背景の輝度差を捉えるのに有効と考えた。

1. Edge features



(a) (b) (c) (d)

2. Line features



(a) (b) (c) (d)

3. Center-surround feature

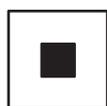


図 3.10 Haar-like 特徴量の形状

3.4.4 EOH 特徴量

(1) 概要

EOH (local Edge Orientation Histogram) 特徴量は、局所領域におけるエッジ勾配の関係に着目した特徴量である^[3-21]。EOH 特徴量の算出に当たり、まず 2.3.2 項の式(2.2), (2.3)に示した水平方向及び垂直方向それぞれの隣接画素の微分(差分)により水平方向微分 f_x 及び垂直方向微分 f_y を求め、式(3.18)によりエッジ方向 θ を算出する。

$$\theta(x, y) = \arctan\left(\frac{f_x(x, y)}{f_y(x, y)}\right) \quad (3.18)$$

得られたエッジ方向 θ は K 段階（本論文では4方向）に量子化を行う。量子化した各エッジ方向 k におけるエッジ強度 $\varphi_k(x,y)$ を式(3.19)により求める。図 3.11 に、算出したエッジ方向ごとに色分けしたエッジ強度画像を示す。

$$\varphi_k(x,y) = \begin{cases} f_{xy}(x,y) & \text{if } \theta(x,y) \in \text{bin}_k \\ 0 & \text{otherwise} \end{cases} \quad (3.19)$$

$$f_{xy} = \sqrt{f_x^2 + f_y^2}$$

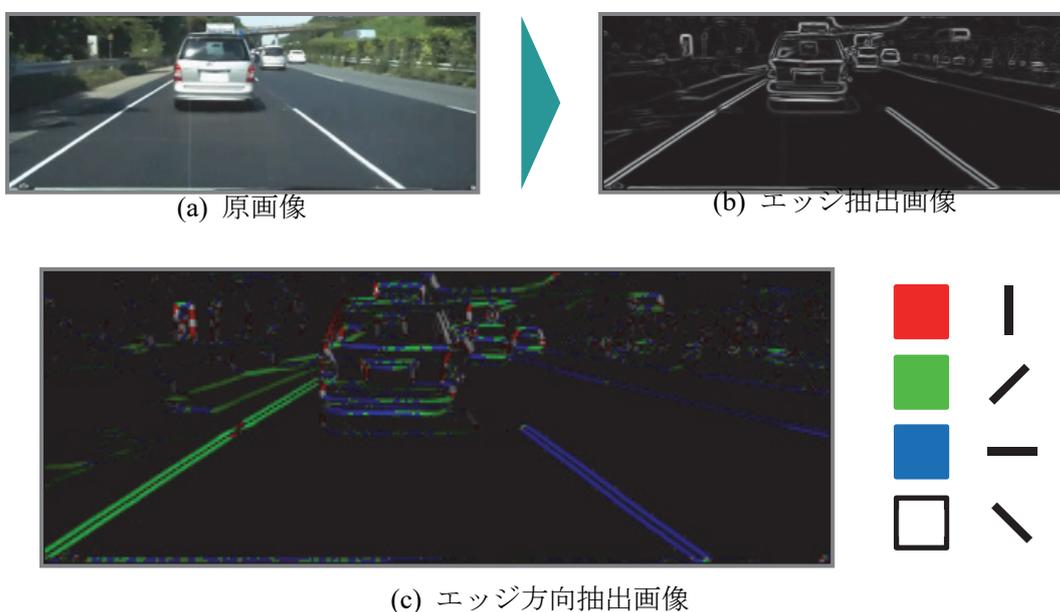


図 3.11 EOH 特徴量算出のためのエッジ方向算出

また、着目する領域 R における各エッジ方向の累積エッジ強度 $E_k(R)$ は式(3.20)により求める。

$$E_k(R) = \sum_{(x,y) \in R} \varphi_k(x,y) \quad (3.20)$$

EOH 特徴量は累積エッジ強度 E_k を用いた3種の特徴量から構成される。以下、それぞれの特徴量の算出方法について述べる。

(a) Edge Orientation Histogram Features (エッジ方向ヒストグラム特徴量)

ある領域 R における, エッジ方向 k_1 に対する累積エッジ強度 $E_{k_1}(R)$ とエッジ方向 k_2 に対する累積エッジ強度 $E_{k_2}(R)$ の比を式(3.21)により求め, これをエッジ方向ヒストグラム特徴量 A_{k_1, k_2} とする (図 3.12)。

$$A_{k_1, k_2} = \frac{E_{k_1}(R) + \varepsilon}{E_{k_2}(R) + \varepsilon} \quad (3.21)$$

式中の ε は 0 による除算を防ぐための値であり, 例えば $\varepsilon = 10^{-5}$ などとする。

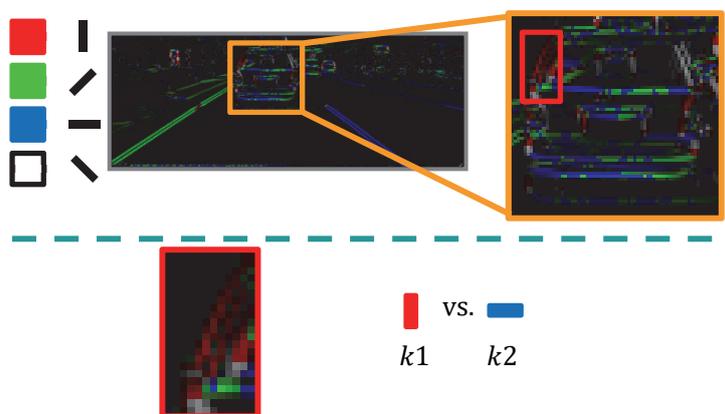


図 3.12 エッジ方向ヒストグラム特徴量

(b) Dominant Orientation Features (有力方向特徴量)

ある領域 R における, エッジ方向 k に対する累積エッジ強度 $E_k(R)$ と全てのエッジ方向に対する累積エッジ強度の比を式(3.22)により求め, これを有力方向特徴量 B_k とする (図 3.13)。

$$B_k = \frac{E_k(R) + \varepsilon}{\sum_i E_i(R) + \varepsilon} \quad (3.22)$$

式中の ε は 0 による除算を防ぐための値であり, 本論文では $\varepsilon = 10^{-5}$ とした。

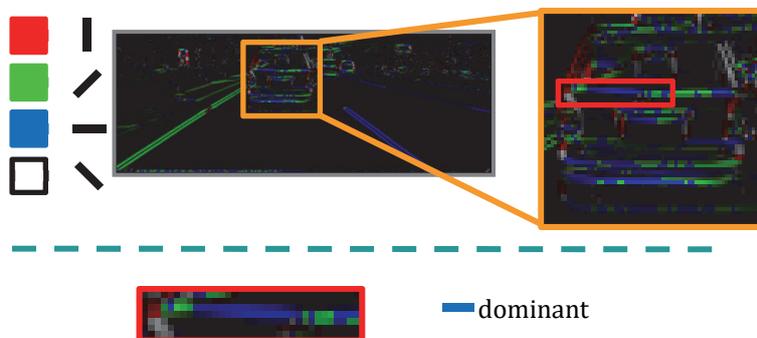


図 3.13 有力方向特徴量

(c) Symmetry Features (左右対称性特徴量)

ある領域 R_1 と、その領域と線対称となる領域 R_2 における、全エッジ方向に対する累積エッジ強度 $E_k(R_1)$ 及び $E_k(R_2)$ を用いて左右対称性を式(3.23)により求め、これを左右対称特徴量 $Symm(R_1, R_2)$ とする (図 3.14)。

$$Symm(R_1, R_2) = \frac{\sum_{k \in K} |E_k(R_1) - E_k(R_2)|}{sizeof(R_1)} \quad (3.23)$$

式中の $sizeof(R)$ は領域 R における画素数を求める関数である。

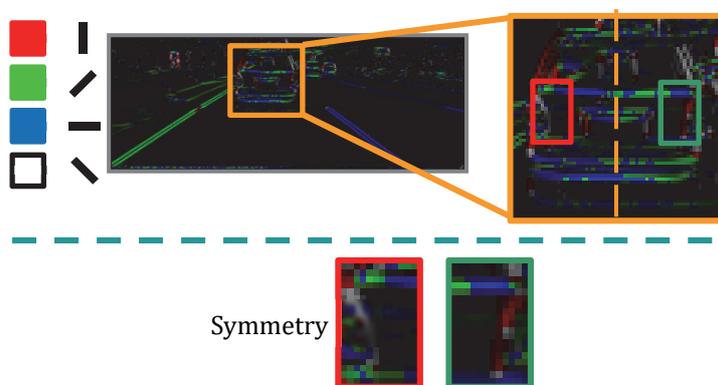


図 3.14 左右対称性特徴量

(2) 本論文での工夫点

Real AdaBoost で EOH 特徴量を学習する場合、累積エッジ強度 E_k は着目領域 R に応じて領域が異なることから、確率密度分布のヒストグラムビン設計が困難となる。そこで本論文では、式(3.24)のようにエッジ強度 $\varphi_k(x, y)$ を着目領域 R とエッジ強度 $\varphi_k(x, y)$ の最大値の積で割ることで、累積エッジ強度 E_k の値域が常に $[0, 1]$ となるように変更を加えたものを用いる。

$$E_k(R) = \frac{\sum_{(x,y) \in R} \varphi_k(x, y)}{sizeof(R) \times \sqrt{255^2 + 255^2}} \quad (3.24)$$

ここで、式中の $sizeof(R)$ は領域 R における画素数を求める関数である。また、 $\sqrt{255^2 + 255^2}$ は f_{xy} がとり得る最大値である。

またエッジ方向ヒストグラム特徴量について、式(3.21)により与えられる比の形では値の変化が急峻であるため、本論文では指数関数を用いた式(3.25)により算出したエッジ方向ヒストグラム特徴量 $A_{k1, k2}$ を用いる。

$$A_{k_1, k_2} = \begin{cases} 0 & \text{if } E_{k_1}(R) = 0 \\ 1 & \text{else if } E_{k_2}(R) = 0 \\ \exp\left(-\frac{E_{k_1}(R) + \varepsilon}{E_{k_2}(R) + \varepsilon}\right) & \text{otherwise} \end{cases} \quad (3.25)$$

3.4.5 HOG 特徴量

HOG (Histogram of Oriented Gradients) 特徴量は、局所領域内におけるエッジ方向ごとのエッジ強度に着目した特徴量である^[3-22]。HOG 特徴量では、複数の画素 (ピクセル) をまとめたものを「セル」、複数のセルをまとめたものを「ブロック」として定義し、ブロック単位での正規化を行う。これにより、部分的な輝度変化などにより画像中のエッジ強度に差が生じるような場合にも頑健な特徴抽出が可能となる。HOG 特徴量の算出手順は、まず EOH 特徴量と同様に 2.3.2 項の式(2.2), (2.3)によりエッジ抽出を行い、式(3.18)によりエッジ方向を算出する。ここで得られたエッジ方向 θ を K 段階 (本論文では 9 方向) に量子化し、複数の画素 (ピクセル) をまとめた「セル」単位でエッジ方向ごとの強度をヒストグラム化する。図 3.15 にセル単位でのエッジ方向ヒストグラム化の概念図を示す。

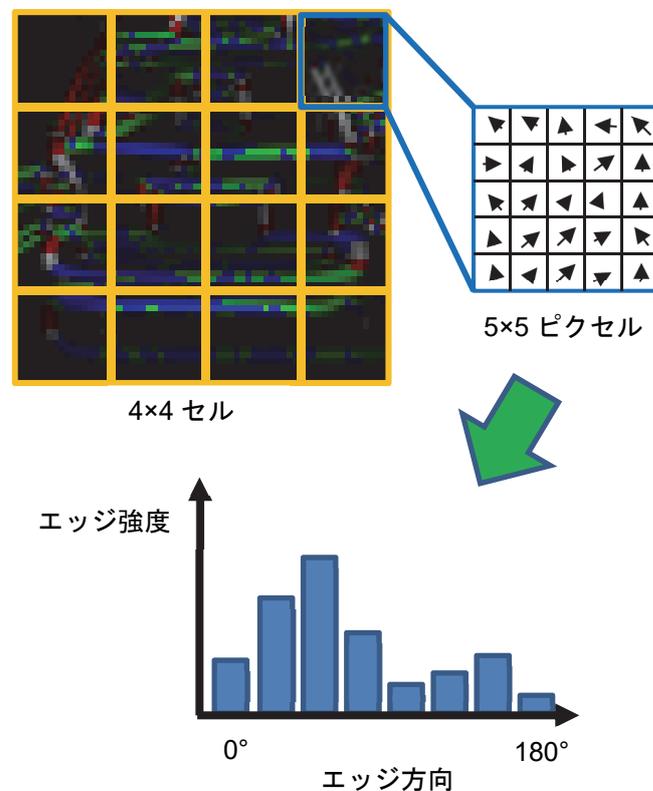


図 3.15 セル単位のエッジ方向ヒストグラム

20×20pixel の画像を想定した場合、1セル当たりのピクセル数を 5×5pixel とすると画像全体は 4×4 セルに分割される。この分割された領域ごとにエッジ方向の強度をヒストグラム化する。セル単位でヒストグラム化したエッジ方向の強度を、複数のセルでまとめた「ブロック」単位で正規化する。例えばブロック領域を 3×3 で定義した場合、ブロック領域には 9 個のセル、すなわち 9 個のヒストグラムが存在することになる。 $q \times q$ のブロック領域で正規化したときのある n 番目の HOG 特徴量 $v(n)$ は式(3.26)を用いて算出する。

$$v(n) = \frac{v(n)}{\sqrt{\sum_{k=1}^{q \times q \times K} v(k)^2 + \varepsilon}} \quad (3.26)$$

ここで、式中の K は量子化するエッジ方向数である。また、式中の ε は 0 による除算を防ぐための値であり本論文では $\varepsilon = 1$ とした。

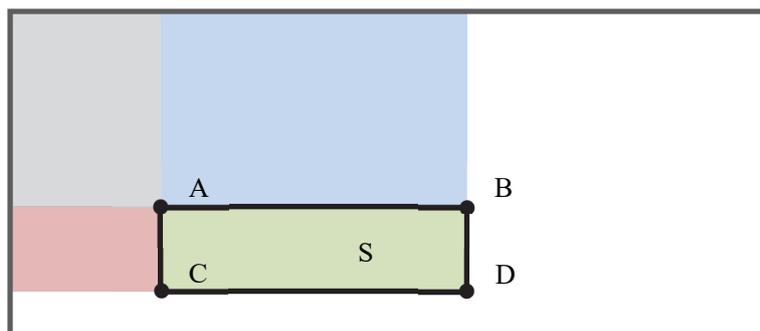
正規化を行うブロック領域を画像中で 1セルずつスライドさせることで、異なる HOG 特徴量を得ることができる。よって、各セルのエッジ方向ヒストグラムは複数回正規化に用いられる。

3.4.6 画像特徴量算出の高速化

Haar-like 特徴量の場合、着目領域内の輝度値の総和や平均を算出する必要があるため、着目する局所領域の大きさによって計算量は大きく異なる。EOH 特徴量や HOG 特徴量の場合も同様に、着目する局所領域内のエッジ方向ごとのエッジ強度を累積する必要があるため、局所領域の大きさによって計算量が大きく異なる。この問題を解決するために、局所領域内の輝度の総和を算出する特徴量では Integral Image^[3-12] (積分画像) が、局所領域内のエッジ方向ごとのエッジ強度を累積する特徴量では Integral Histogram^[3-23] (積分ヒストグラム) が提案され、用いられている。積分画像や積分ヒストグラムを用いることで、計算量が局所領域の大きさに依らなくなり常に一定とすることができるため、高速な特徴量の算出が可能となる。

(1) 積分画像

積分画像とは、画像領域内の左上から順に輝度値を累積した画素値をもつ画像のことである。ある画像に対して任意領域の輝度値の総和 S を求めたいとき、積分画像により領域の大きさに関わらず演算回数を一定とすることができる。図 3.16 に積分画像の概念図を示す。



$$S = D - B - C + A$$

図中の A, B, C, D は、画像の左上から、各座標までの累積画素値を表す

図 3.16 Integral Image (積分画像) の概念図

(2) 積分ヒストグラム

積分ヒストグラムは積分画像を応用したもので、画像領域内の左上から順にエッジ強度を累積し、エッジ方向ごとに作成したものが積分ヒストグラムとなる。ある画像に対して任意領域のあるエッジ方向におけるエッジ強度の総和を求めたいとき、積分ヒストグラムを用いることで領域の大きさに関わらず演算回数を一定とすることができる。

3.4.7 車両識別処理

本論文の車両識別処理は「車両・非車両の識別」「車両下影の選別」から構成する。車両・非車両の識別とは、抽出した全ての車両下影候補に対して、車両下影候補領域の上部を網羅するように車両識別器を適用し、車両と識別した領域には車両識別器の外枠に等しい検出矩形を画像上に残し、非車両と識別した領域には何も残さない処理である。図 3.17 に車両・非車両の識別の画像例を示す。ここで、車両識別器を車両下影の上部領域に適用しただけでは、図 3.17 に示すように 1 つの車両下影に対して複数の検出矩形が存在することがある。複数の検出矩形がある状態では先行車両領域を一意に決定できないため検出矩形の統合処理を行う。一般に検出矩形の統合処理は、Mean-shift クラスタリング^[3-24]などのクラスタリ

ング手法により分類された検出矩形のクラスタごとに行う。しかし本論文においては、検出矩形が必ず対応する車両下影を持つことから、車両下影を検出矩形のクラスタとみなすことができる。この考え方より、統合処理は車両下影ごとに行い、存在する検出矩形の横位置、縦位置、スケールそれぞれについての識別器の出力を重みとした加重平均値を統合結果とした。なお、検出矩形の横位置、縦位置は矩形中央下端の座標をもって算出する。また検出矩形の統合処理では、統合する検出矩形の数が閾値未満であれば非車両として処理することで誤識別の抑制も同時にはかれる。図 3.18 に検出矩形の統合処理の画像例を示す。



図 3.17 車両・非車両の識別の画像例



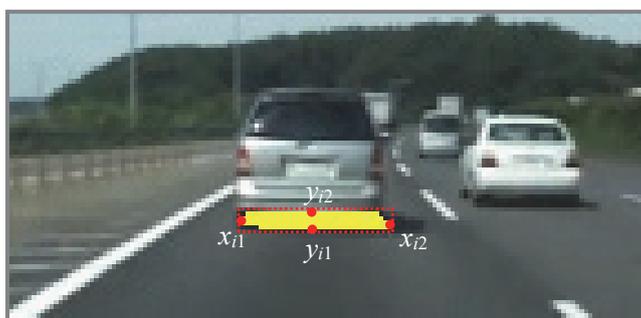
図 3.18 車両識別結果の統合例

車両下影の選別とは、車両・非車両の識別により検出矩形が残った車両下影候補のみを正しい車両下影として抽出し、それ以外の車両下影候補を車両下影ではないとして除去する処理である。このとき、複数の車両下影候補の上部領域に検出矩形が残ることがあるが、本論文は先行車両検出であるため一意に決定したい。そこで、車両下影が車幅程度の大きさを持つという特徴を利用し、車両下影の横幅と検出矩形の幅の差が小さいかつ、一つの車両下影に残った検出矩形の信頼度の平均が最大のものを最終的な検出結果として検出矩形の選別を行う。以下、車両下影候補領域及び車両識別器の適用について述べる。

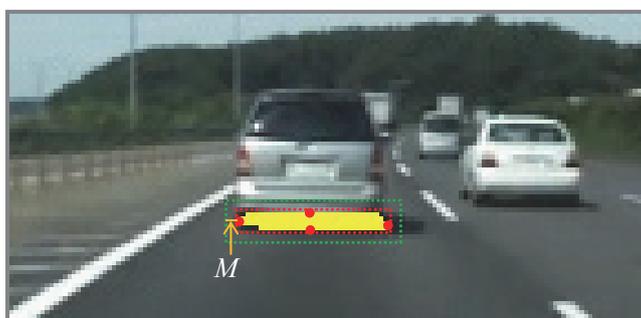
(1) 車両下影候補領域

抽出された I 個の車両下影候補 S に対し, i 番目の車両下影候補 S_i の x 方向の最小値を x_{i1} , 最大値を x_{i2} , y 方向の最小値を y_{i1} , 最大値を y_{i2} とする。この 4 点をもって車両下影候補の領域を確定する。図 3.19(a)に車両下影候補領域確定のイメージを示す。

上述した車両下影候補領域上部に対して車両識別を行った場合, 抽出した車両下影候補の横幅が実際の車幅より短いなどのケースに対応できないことがある。このことから, 車両下影候補領域を決める 4 点それぞれにマージン M を加えたものを, 改めて車両下影候補領域とする。図 3.19(b)に改めて決定する車両下影候補領域のイメージを示す。



(a) 車両下影抽出結果から得られる車両下影候補領域のイメージ



(b) 車両識別時に用いる車両下影候補領域のイメージ

図 3.19 車両下影候補領域の定義

(2) 車両識別器の適用

車両識別器を車両下影候補領域の左下端にあわせて車両下影候補領域をはみ出さないようにラスタ走査し、最終的に車両下影候補領域の右上端までの走査を行う。図 3.20 に車両識別器適用のイメージを示す。

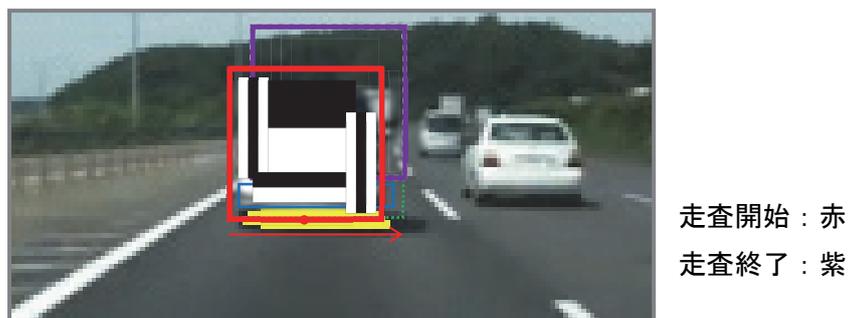


図 3.20 車両識別器適用のイメージ

また、車両識別器による車両下影候補領域上部の走査には、車両識別器のスケールが重要な要素となる。この車両識別器のスケールについて、本論文では先行車両の画像上でのおよその車幅をもとに決定する。これにより効率的な車両識別が可能となる。以下に先行車両の画像上での車幅の求め方について述べる。

第 2 章で提案した白線抽出により消失点座標 Hr が定まる。画像に対し水平方向を x 軸、鉛直方向を y 軸とする直交座標系で考えたとき、消失点 y 座標 Hr に加え、車両下影候補の y 座標を用いることで先行車両の画像上での車幅 $ws[\text{pixel}]$ は式(3.27)により求めることができる。

$$ws = -\frac{vw}{Hr}y + vw \quad (3.27)$$

ここで、式中の vw は、 $y = 0$ における先行車両の車幅 $[\text{pixel}]$ を表す。本論文では試験的に求めた値として $vw=150$ に設定する。

3.5 先行車両検出実験

車両下影に着目した車両識別による先行車両検出の有効性を検証するために提案手法のほか2つの手法との比較実験を行う。比較に用いる手法には、近年の画像認識分野において先端を走る深層学習（deep learning）を用いた一般物体検出のモデルを採用する。物体検出モデルのなかでもシンプルな構造から、比較的高速かつ軽量化によるエッジデバイスなどへの実装が見込める SSD（Single Shot multibox Detector）^[3-25]を用いた。

SSD は、脳の神経細胞（ニューロン）の情報伝達の仕組みをモデル化した数理モデルである NN（Neural Network）に脳の視覚野に関する神経科学の知見を取り入れた、CNN(Convolutional Neural Network：畳み込みニューラルネットワーク)の一モデルであり、画像中から高速な物体検出を実現するモデルとして提案された。ベースネットワークと呼ぶ特徴抽出のための CNN により基本となる特徴マップ(ベースマップ)を画像から抽出し、Extra Feature Layers と呼ぶ畳み込み層 8 層を用いて 2 回畳み込むごとにスケールを縮小させ、ベースマップからスケールの異なる特徴マップを複数抽出する。こうして得られたマルチスケールの特徴マップに対して位置推定及びクラス推定を行うための畳み込みを行う点が SSD の特徴であり、これにより画像中の様々なスケールの物体を検出できる。文献[3-25]では、画像識別用の CNN として成果を上げている VGG^[3-26]の一種、VGG-16 をベースネットワークに採用している。SSD はベースネットワークの変更が想定されたアーキテクチャとなっており、このベースネットワークにエッジデバイス向けとして提案された軽量化 CNN の MobileNet v1^[3-27]を採用することで、精度低下を抑えつつも高速化を実現した SSD が知られている。

3.5.1 実験条件

実験の諸条件を以下に示す。

○PC の仕様

- CPU Intel Corei7 6800K 3.40GHz
- メモリ 32GB
- GPU NVIDIA TITAN RTX 1770 MHz 24 GB
- OS Windows 10 64bit

○実験シーン（動画）：QVGA（320×240 pixel），30 fps

実験には以下のシーンを使用した。なお、高速道路昼晴天シーン及び一般道夜雨天シーンは第2章で使用したものと同様のシーンである。

- 高速道路 昼 晴天 1 シーン 1,000 frames
- 一般道 夜 雨天 1 シーン 1,000 frames

○比較手法

- SSD-VGG ベースネットワークに VGG-16 を用いた SSD
- SSD-Mobile ベースネットワークに MobineNet v1 を用いた SSD
- 提案手法 白線抽出による処理領域限定の後、車両下影抽出及び車両識別

比較に用いる SSD には、深層学習フレームワークの一つ Pytorch^[3-28]で構築された github で公開の学習済みモデル^[3-29]を用いた。これらのモデルは物体検出用のデータセットの一つ Pascal VOC^[3-30]の 20 クラス {aeroplane, bicycle, bird, boat, bottle, bus, car, cat, chair, cow, diningtable, dog, horse, motorbike, person, pottedplant, sheep, sofa, train, tvmonitor} を学習したものであり、本実験では“car”に対する出力のみを用いた。

提案手法の車両識別器は、車両画像 944 枚を 2 種類のデータ拡張方法で水増しした計 2832 枚と非車両画像 2207 枚を用い、Real AdaBoost により Haar-like 特徴量、EOH 特徴量、HOG 特徴量を選択的に学習し構築した。弱識別器の数は 25 個であり、選択的に学習した結果全ての弱識別器が EOH 特徴量を採用した。EOH 特徴量に本論文独自の改良を加える前は Haar-like 特徴量が 14 個、EOH 特徴量が 11 個であったため、本論文で加えた改良が EOH 特徴量の表現力向上に対して有効に働いている。

○評価方法

まず何らかの検出があり、かつ検出矩形と正解矩形との式(3.28)で定義される Jaccard 係数が 0.5 以上の場合を正検出、満たさない場合を誤検出、何も検出しない場合を未検出として式(3.29)により Precision (適合率) を、式(3.30)により Recall (再現率) を算出する。

$$J(A_e, A_g) = \frac{|A_e \cap A_g|}{|A_e \cup A_g|} \quad (3.28)$$

ここで、 A_e と A_g はそれぞれ、検出領域と実測した正解領域である。 A_e と A_g の領域が完全に一致したとき、Jaccard 係数は 1 となる。なお Jaccard 係数は、物体検出分野において IoU (Intersection over Union) として知られる評価指標であり、一般的な物体検出においては 0.5 以上で良い検出結果とされる^[3-31]。

$$\text{Precision} = \frac{\text{正検出数}}{\text{正検出数} + \text{誤検出数}} \quad (3.29)$$

$$\text{Recall} = \frac{\text{正検出数}}{\text{正検出数} + \text{未検出数}} \quad (3.30)$$

ただし、SSD は対向車両等も検出できるため、自車両走行レーン以外の車に対する検出は誤検出に含まないこととする。

2つ目の評価基準として x 座標、 y 座標、車幅 w それぞれの検出誤り画素を用いる。 x 座標、 y 座標については車両下影の位置に基準を置くため、検出矩形の中央下端で算出する。なお車高 h に関しては、SSD を用いた手法では推定可能であるが、本論文の提案手法は正方形のスケールで車両を検出するものであり、本実験用に用意した各動画に対する正解矩形も正方形で用意したため評価には用いない。また検出誤り画素は、正検出のみを用いて算出する。

3.5.2 実験結果及び考察

(1) 高速道路昼晴天シーンにおける実験結果の比較

実験には、建物等の影が繰り返し現れるシーンを利用した。高速道路であるため車間距離が広く、先行車両が比較的遠方にあることもシーンの特徴である。表 3.2 に Precision, Recall 及び検出誤り画素をまとめたものを示す。図 3.21～図 3.23 に検出結果の画像例を示す。

表 3.2 に示すように、SSD を用いた各手法では誤検出が少なく、Precision が 0.95 以上となった。SSD-VGG では未検出も少なく Recall も 0.99 となり、全手法中最高の性能であった。しかし軽量化モデルの SSD-Mobile 手法ではほとんどが未検出となり、Recall が 0.02 と

なった。これは、小さい物体を検出するための特徴マップが大きい物体を検出するための特徴マップに対して浅い特徴抽出しかされていないため小さい物体に弱いという、SSD の欠点に関する。既に述べたとおり、本実験シーンは車間距離が広いいため、先行車両が非常に小さい。SSD-Mobile では、本論文で対象とするような小さい物体を検出するのに十分な特徴が抽出できなかつたと推測する。また、どちらの手法も GPU では 30ms 程度の処理時間であるが、CPU では処理時間が約 5 倍の差があり、SSD-Mobile での軽量化の効果が確認できる。SSD を用いた手法に比べ、提案手法では誤検出が生じ Precision が低下するものの 0.83 程度あり、CPU 平均処理時間を 20ms 以内に抑えつつも Recall を 0.83 とし、SSD-Mobile よりも有効な結果を得た。

図 3.21(b)に示すように、SSD-Mobile では画像上で約 40pixel の幅を持つ車両を検出できたが、図 3.22(b)に示すように画像上で約 30pixel の幅を持つ車両を検出できなかった。また、図 3.22(c)より、提案手法では、画像中に黄色で示す車両下影候補から車両識別により正しく車両下影を選別できた。しかし図 3.23(b)に示すように、車両識別により誤った影を選別することによる誤検出が発生している。本論文では 3.4.7 項で述べたように先行車両の検出矩形を一意に決定するための矩形選別を行うが、図 3.23(c)に示すように矩形選別前には先行車両を検出できている。そのため、Real AdaBoost で学習する非車両画像サンプルのなかに、この例のように車両を一部含むものを多く含ませることで、車両を一部のみ含む領域における識別器の車両らしさの出力が低下し、正しい車両下影の選別が見込める。

表 3.2 高速道路昼晴天シーンの実験結果

	SSD-VGG	SSD-Mobile	提案手法
Precision	1.0	0.95	0.83
Recall	0.99	0.02	0.83
平均 x 座標誤差 [pixel]	1.16	3.21	1.45
平均 y 座標誤差[pixel]	0.56	0.39	2.09
平均車幅誤差 [pixel]	2.56	11.4	2.37
最大 x 座標誤差 [pixel]	4	5	8
最大 y 座標誤差[pixel]	2	1	6
最大車幅誤差 [pixel]	8	11	9
CPU 平均処理時間 [ms]	1405	297	18.5
GPU 利用時平均処理時間 [ms]	24.2	30.3	-



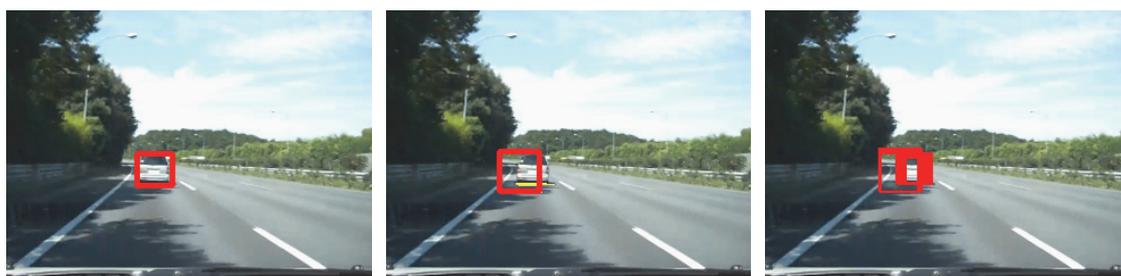
(a) SSD-VGG : 正検出 (b) SSD-Mobile : 正検出 (c) 提案手法 : 正検出

図 3.21 全手法での正検出例 (高速道路昼晴天)



(a) SSD-VGG : 正検出 (b) SSD-Mobile : 未検出 (c) 提案手法 : 正検出

図 3.22 車両識別の成功による提案手法の正検出例 (高速道路昼晴天)



(a) SSD-VGG : 正検出 (b) 提案手法 : 誤検出 (c) 提案手法 (矩形選別前)

図 3.23 車両識別の失敗による提案手法の誤検出例 (高速道路昼晴天)

(2) 一般道夜雨天シーンにおける実験結果の比較

実験には、雨であることに加えて先行車両がブレーキを踏み、大きな照明変動が生じるシーンを利用した。表 3.3 に Precision, Recall 及び検出誤り画素をまとめたものを示す。図 3.24 ~ 図 3.26 に検出結果の画像例を示す。

表 3.3 に示すように、高速道路昼晴天シーン同様、SSD を用いた各手法では誤検出が少なく、Precision が 0.97 以上となった。また SSD を用いた各手法では、未検出が多く発生し、Recall は 0.7 未満となった。未検出が生じたフレームとしては、フロントガラスに付着した雨滴の影響で画像がぼやけるフレームや、同様に雨滴の影響で街灯の光が強調されたフレームなどである。どちらの手法も高速道路昼晴天シーン同様、GPU では 30ms 程度の処理時間であるが、CPU では処理時間が約 4 倍の差があり、SSD-Mobile での軽量化の効果が確認

できる。SSD を用いた手法に比べ、提案手法では Precision は一番低いものの 0.94 であり、CPU 平均処理時間を 20ms 以内に抑えつつも Recall を 0.90 とし、全手法中最も未検出を抑制でき、SSD よりも有効な結果を得た。

図 3.24 は全ての手法で正検出となった例であり、結果より SSD-VGG が最も正確に車両領域を推定できている。さらに図 3.24(c)より、夜間雨天に加え、先行車両のブレーキランプが路面に反射するような路面環境下においても、提案手法により車両下影を抽出できた。図 3.25(b)に示すように、このフレームにおいて SSD-Mobile は先行車両を正検出しているものの隣接領域を誤検出している。これは、駐車してあるトラックの前方が画像左側にわずかに映っているシーンであり、その領域から抽出した特徴に車両らしさが含まれていたと推測する。また図 3.25(c)より、提案手法では、わずかではあるが生じている雑音を含んだ車両下影候補から車両識別により正しく車両下影を選別できた。しかし図 3.26(b)に示すように、車両識別により誤った影を選別することによる誤検出が発生している。検出矩形の中央付近に車両全体を含むが、領域内で車両が占める割合は小さい。ここで、学習した弱識別器のなかでも特に有効性が高い初期のものに着目すると、領域を縦で切った時の中央における水平エッジが占める割合や、領域を横で切った時の中央における水平エッジと垂直エッジの比を用いている。よって、図 3.26(b)の例は、領域中央付近に車両全体が含まれているため、識別器の出力が大きくなり誤検出したと推測できる。したがって、このように車両を中央に含むような画像も非車両画像としてサンプルに加えることで精度向上が見込める。

表 3.3 一般道夜雨天シーンの実験結果

	SSD-VGG	SSD-Mobile	提案手法
Precision	0.99	0.97	0.94
Recall	0.67	0.41	0.90
平均 x 座標誤差 [pixel]	2.32	1.71	5.91
平均 y 座標誤差[pixel]	4.39	1.94	0.95
平均車幅誤差 [pixel]	3.03	3.75	8.40
最大 x 座標誤差 [pixel]	17	8	16
最大 y 座標誤差[pixel]	13	7	5
最大車幅誤差 [pixel]	16	17	21
CPU 平均処理時間 [ms]	1334	314	17.7
GPU 利用時平均処理時間 [ms]	24.2	32.0	-



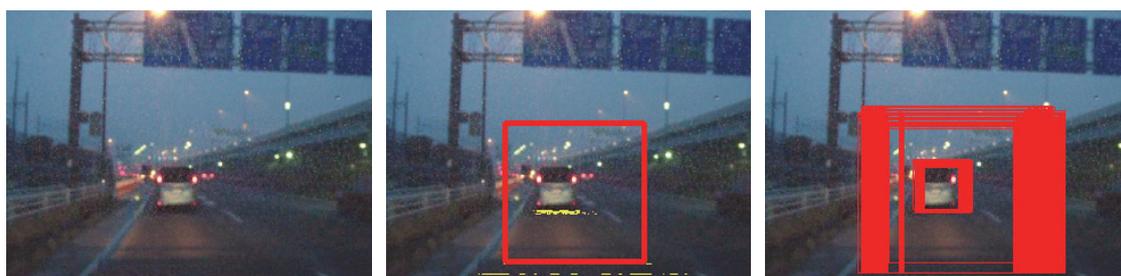
(a) SSD-VGG : 正検出 (b) SSD-Mobile : 正検出 (c) 提案手法 : 正検出

図 3.24 全手法での正検出例 (一般道夜雨天)



(a) SSD-VGG : 正検出 (b) SSD-Mobile : 正検出+誤検出 (c) 提案手法 : 正検出

図 3.25 車両識別の成功による提案手法の正検出例 (一般道夜雨天)



(a) SSD-VGG : 未検出 (b) 提案手法 : 誤検出 (c) 提案手法 (矩形選別前)

図 3.26 車両識別の失敗による提案手法の誤検出例 (一般道夜雨天)

3.6 まとめ

本手法の特徴は、車両特徴として車両下影に着目し、処理コストの高い機械学習を用いた識別器による車両識別処理を効果的に適用することで、高速かつ高精度な車両下影抽出としての車両検出処理を実現した点にある。高速道路昼晴天シーン及び一般道夜雨天シーンの動画像を用いた実験により、提案手法は CPU で 20ms 以内に完結する処理ながら 0.8 以上の Precision と Recall を達成した。比較的軽量な物体検出モデルの一つである SSD-VGG は両シーンで 0.99 以上の Precision を達成したが、一般道夜雨天シーンで Recall が 0.67 となり、提案手法よりも未検出が多く安定しない結果となった。また本論文において重要となる y 座標誤差で比較しても、提案手法の方が SSD-VGG よりも安定する結果を得た。

文 献

- [3-1] 山田憲一・伊東敏夫：「エッジ画像の濃度投影による車両の一補足手法」，電気学会論文誌 E, Vol. 118, No. 6, pp. 327-332 (1998)
- [3-2] 渡邊信太郎・関真規人・鹿毛裕史・鷺見和彦：「コンテキストを用いた動画像からの対象認識の高精度化」，電子情報通信学会論文誌 D, Vol. J92-D, No. 4, pp. 521-530(2009)
- [3-3] 西本至孝・泉 隆：「影抽出に基づく車両検出について」，電気学会ITS研究会, ITS-06-14, pp.7-11 (2006)
- [3-4] 張 宇・岡田友司・泉 隆：「車両前方画像における影に着目した先行車両抽出—レーン検出手法改善と路面特徴分析による抽出精度向上—」，平成21年電気学会産業応用部門大会YPC, Y-96 (2009)
- [3-5] 関 弘翔・泉 隆：「車両前方画像における影に着目した先行車両抽出」，電気学会論文誌D, Vol. 136, No. 1, pp.9-16 (2016)
- [3-6] H. Mori and N. M. Charkari : “Shadow and Rhythm as Sign patterns of Obstacle Detection”, in Proc. IEEE International Symposium on Industrial Electronics(ISIE), pp. 271-277 (1993)
- [3-7] C. Tzomakas and W. von Seelen: “Vehicle Detection in Traffic Scene Using Shadows”, Technical Report 98-06, Institut für Neuroinformatik, Ruht-Universität, Bochum, Germany (1998)
- [3-8] S.-S. Huang, C.-J. Chen, P.-Y. Hsiao, L.-C. Fu: “On-Board Vision System for Lane Recognition and Front-Vehicle Detection to Enhance Driver’ s Awareness” , in Proc. IEEE International Conference on Robotics and Automation(ICRA), Vol.3, pp.2456-2461 (2004)
- [3-9] Z. Liu, Z. Sun, H. He: “On-road Vehicle Detection Fusing Radar and Vision” , in Proc. IEEE International Conference on Vehicular Electronics and Safety (ICVES), pp.150-154 (2011)
- [3-10] Nur Shazwani A., M. M. Ibrahim, N. M. Ali, Nur Fatin Izzati Y.: “Vehicle Detection Based on Underneath Vehicle Shadow Using Edge Features” , in Proc. IEEE International Conference on Computer Science Education (ICCSE), pp. 407-412 (2016)
- [3-11] V. Vapnik and A. Lerner: “Pattern recognition using generalized portrait method”, Journal of Automation and Remote Control, Vol.24, pp.774-780 (1963)

- [3-12] P. Viola and M. Jones: “Rapid object detection using a boosted cascade of simple features” ,
in Proc. IEEE Conf. on Computer Vision and Pattern Recognition(CVPR), Vol.1, pp.511-518
(2001)
- [3-13] R. E. Schapire and Y. Singer: “Improved Boosting Algorithms Using Confidence-rated
Predictions” , Journal of Machine learning, Vol.37, No.3, pp.297-336 (1999)
- [3-14] F. Ahmed, E. Hossain, A.S.M. Hossain, and ASM. Shihavudd: “Compound Local Binary
Pattern (CLBP) for Facial Expression Recognition”, in Proc. IEEE International Symposium
on Computational Intelligence and Informatics(CINTI), pp. 391-395 (2011)
- [3-15] T. Ojala, M. Pietikäinen and D. Harwood: “Performance evaluation of texture measures with
classification based on Kullback discrimination of distributions”, in Proc. IEEE International
Conference on Pattern Recognition(ICPR), Vol.1, pp.582-585 (1994)
- [3-16] Y. Freund and R. E. Schapire: “A Decision-Theoretic Generalization of On-Line Learning
and an Application to Boosting” , Journal of Computer and System Sciences, No.1, Vol.55,
pp.119-139(1997)
- [3-17] A. Bhattacharyya, “On a measure of divergence between two statistical populations defined by
their probability distributions”, Journal of Bulletin of the Calcutta Mathematical Society,
Vol.35, pp.99-110 (1943)
- [3-18] 谷川昌司・日高章理・佐野夏樹・西田健次・栗田多喜夫:「矩形特徴による弱識別器
のブースティングによる対象検出手法の汎化性能向上のための工夫と車載カメラの
映像中の車の検出への応用」, 第11回画像センシングシンポジウム講演論文集, E-10,
pp.139-142 (2005)
- [3-19] R. Lienhart and J. Maydt: “An Extended Set of Haar-like Features for Rapid Object Detection” ,
in Proc. IEEE Int. Conf. on Image Processing(ICIP), Vol.1, pp.900-903(2002)
- [3-20] 山下隆義・勞 世竝・川出雅人:「Online Real Boostingによる人物追跡」, 情報処理学
会論文誌 コンピュータビジョンとイメージメディア, Vol.1, No.1, pp.73-82(2008)
- [3-21] K. Levi and Y. Weiss: “Learning Object Detection from a Small Number of Examples: the
Importance of Good Features” , in Proc. IEEE Conf. on Computer Vision and Pattern
Recognition(CVPR), Vol.2, pp.53-60 (2004)

- [3-22] N. Dalal and B. Triggs: “Histograms of Oriented Gradients for Human Detection” , in Proc. IEEE Conf. on Computer Vision and Pattern Recognition(CVPR), Vol.1, pp.886-893 (2005)
- [3-23] F. Porikli: “Integral Histogram: A Fast Way to Extract Histogram Features” , in Proc. IEEE Conf. on Computer Vision and Pattern Recognition(CVPR), Vol.1 pp.829-836 (2005)
- [3-24] Y. Cheng: “Mean shift, mode seeking, and clustering” , IEEE Trans. on Pattern Analysis and Machine Intelligence(PAMI), Vol.17, No.8, pp.790-799 (1995)
- [3-25] W. Liu, D. Anguelov, D. Erhan, C. Szegedy, S. E. Reed, C.-Y. Fu, and A. C. Berg: “SSD: single shot multibox detector”, in Proc. European Conference on Computer Vision (ECCV), pp.21-37 (2016)
- [3-26] K. Simonyan and A. Zisserman: “Very deep convolutional networks for large-scale image recognition”, arXiv preprint arXiv:1409.1556 (2014)
- [3-27] A. G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, M. Andreetto, H. Adam: “MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications”, arXiv preprint arXiv:1704.04861 (2017)
- [3-28] A. Paszke, S. Gross, F. Massa, A. Lerer, J. Bradbury, G. Chanan, T. Killeen, Z. Lin, N. Gimeshein, L. Antiga, A. Desmaison, A. Kopf, E. Yang, Z. DeVito, M. Raison, A. Tejani, S. Chilamkurthy, B. Steiner, L. Fang, J. Bai, S. Chintala: “PyTorch: An imperative style, high-performance deep learning library”, Advances in Neural Information Processing Systems 32 (NIPS2019), pp.8024-8035 (2019)
- [3-29] Github : 「qfgaohao / pytorch-ssd」 , <https://github.com/qfgaohao/pytorch-ssd> (2020-03)
- [3-30] M Everingham, L Van Gool, CKI Williams, J Winn, A Zisserman : “The PASCAL Visual Object Vlasses (VOC) Challenge”, International Journal of Computer Vision,Vol.88 No.2, pp.303-338 (2010)
- [3-31] 原田達也 : 「機械学習プロフェッショナルシリーズ 画像認識」, 講談社 (2017)

第4章 Particle Filter による影らしさと車両らしさを考慮した車両下影追跡

4.1 物体追跡の関連研究と本研究の位置づけ

本研究では、車内に設置した車載単眼カメラを用いて取得した車両前方画像に対して画像処理を行うことにより先行車両検出を実現する。第3章で述べた先行車両検出の誤検出の改善をはかり、車両下影の抽出精度を向上させることを目的に車両下影追跡を行う。以前より影を抽出する研究は多数あるが、その目的のほとんどは別の対象物を検出するうえで雑音となる影の除去である^{[4-1][4-2]}。よって、本研究のように影を抽出対象とする研究は少なく、追跡対象にまでする取り組みはほとんど見受けられない。

画像情報を利用した物体追跡手法として古くから利用されるものには特徴点に基づいて追跡する手法^[4-3]や領域に基づいて追跡する手法^{[4-4][4-5][4-6][4-7]}がある。車両や人などを効率的に追跡するためには領域に基づいた手法が用いられることが多く、なかでも長らく代表的であった手法に、局所探索法に基づく Mean Shift^{[4-4][4-5]}、確率的探索法に基づく Particle Filter (PF)^{[4-6][4-7]}を用いたものがある。Mean Shift は極値探索の手法であり、局所的最適解に必ず収束することが保証されている。すなわち、大域的最適解であることは保証されない。PF は、モンテカルロ法により確率的に探索する手法であり、多数のサンプル点に対して尤度と呼ばれる対象としての尤もらしさを計算し、尤度を重みとしたサンプル点の重心計算（加重和計算）により物体を追跡する。この手法は局所解にとらわれることはないが、最適解に収束する保証がなく、精度良く近似を行うためには計算するサンプル点を十分に増やす必要がある。近年では、領域に基づいた追跡手法として Tracking-by-detection といわれる、検出に基づいた追跡手法^{[4-8][4-9][4-10][4-11]}の発展が著しい。これらの手法は、追跡とは別のタスクである物体検出などで研究されてきた識別器 (Classifier) などを用いて各フレームで検出し対応付けることで追跡を行う考え方が基になっている。追跡対象の画像領域領域を正解サンプル、その周辺領域（背景）を不正解サンプルとして利用し、追跡対象と背景を区別できる

ように識別器関連フィルタをオンライン学習することで追跡対象に特化させる手法が主流である。このとき、追跡精度向上のために、追跡領域の周辺に無数に存在する不正解サンプルを多く学習に取り入れると、それだけ処理時間の増加につながるため、追跡精度と処理時間はトレードオフとなる。よって物体追跡手法においては、リアルタイム性を満足しながら、いかに多くの不正解サンプルを学習に取り込むかという点が、一つの重要な要素といえる。学習サンプルの収集に関しては図4.1(a)に示すようにランダムサンプリングを採用するのが一般的であったが^{[4-9][4-10]}、学習サンプルを正解サンプルに対する巡回行列（循環シフト行列）の考え方で生成し、密なサンプリング（図4.1(b)）を近似的に与えると（図4.1(c)）、周波数領域においては学習が容易になるという手法が提案された^[4-12]。この手法を基にして、KCF（Kernelized Correlation Filter）^[4-13]という物体追跡手法が提案され、先進的な物体追跡手法の一つとなっている。

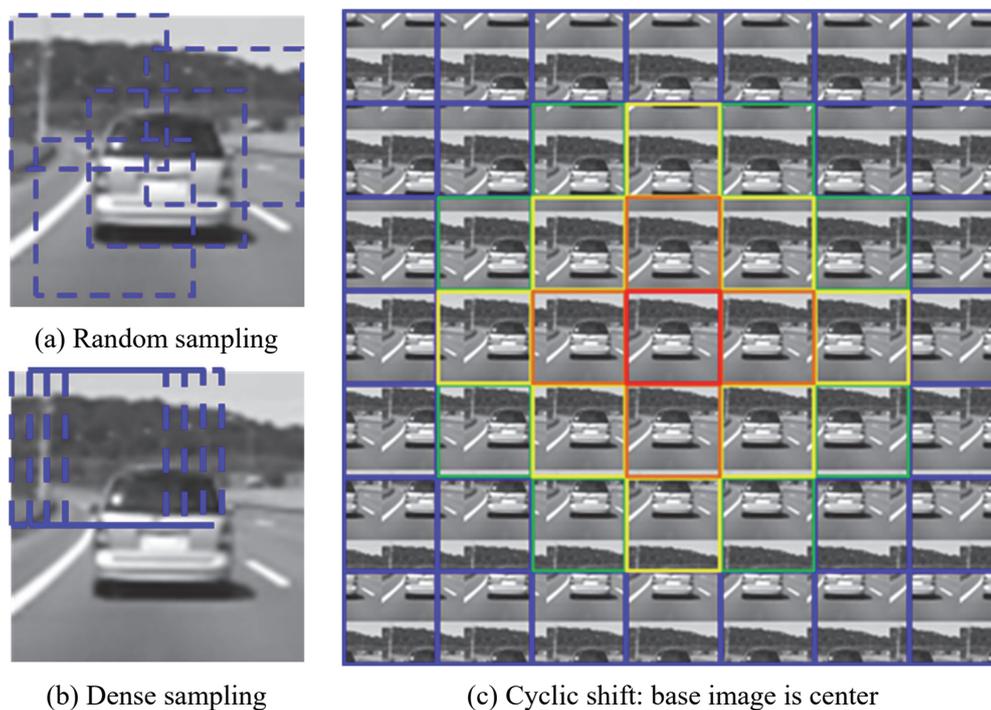


図 4.1 サンプリング手法

本論文の追跡対象である車両下影は、車両領域を取り出した際に一部として含むため、領域に基づいた車両追跡により影も合わせて追跡できる。しかし、領域に基づいた追跡は通常、物体領域の中心を精度良く捉えられるようにするため、一般的な追跡手法では物体領域に対して端に位置する影の特徴は重要視されないことが多い。また、車両背面のように形状を

表す特徴が良く現れる領域に対して、車両下影は現れる特徴も少なく、背景に紛れやすいため、車両下影を領域中心においた追跡では車両を領域中心においた追跡ほどの性能が発揮できない。よって車両下影を精度良く追跡するためには、車両の追跡と車両下影の追跡を同時に行うことが最良であると考えた。

これを実現するために本論文では、複雑な特徴設計をその構造の柔軟さから容易に扱うことができる PF を応用して、影に着目した先行車両追跡手法を提案する。

4.2 影を利用した先行車両追跡の関連研究と本研究の位置づけ

PF は、状態の時系列変化を予測する時系列フィルタリングの一種で、コンピュータビジョンにおける移動体追跡を実現する手法として成果をあげている。複数のサンプル点 (Particle : 粒子) を用意し、初期化ののち、予測、重み付け、リサンプリング処理を繰り返すことで、粒子の状態を更新しながら動画像中の物体追跡を行う。PF は、追跡対象としての尤もらしさを表す尤度から算出する重みに基づいて物体追跡を行うため、尤度特徴の設計が重要となるが、尤度さえ適切に設計できれば状態空間を自由に設定できる柔軟性に富んだ追跡アルゴリズムである。PF により影を利用して先行車両追跡を行う関連手法として文献[4-14][4-15]がある。

Wan らの手法^[4-14]は、白線抽出により処理領域を大まかに路面上へ限定し、この領域内において、対称性、影、エッジという尺度から 3 種類の車両らしさの分布を算出するものである。まず理想的には車両背面の画素値が左右対称となるため、各画素の左右 20pixel を探索範囲として輝度値により処理領域内の対称性の確率分布を算出する。次に車両下影の確率分布を得るために、処理領域内で低輝度画素を抽出する。そのうえで、車両下影らしさは低輝度画素が垂直方向の正規分布で拡がると仮定して各低輝度画素において確率分布を算出し、領域内で足し合わせて正規化することで車両下影らしさの確率分布を算出する。対称性や影らしさは、エッジ情報を含まない黒い塊などでも高くなることが考えられるため、エッジの量に基づく車両らしさの確率分布を算出し、最後にそれらを組み合わせた確率分布を尤度として、PF により追跡する手法である。対称性、低輝度、エッジ量の分布という、特定の車両の特徴ではなく、どのような車両にも成り立つ特徴を基に追跡している。すなわち、この手法は先行車両の並走など、似たような特徴が多数分布する場合に追跡を誤る恐れが

ある。また Chan らの手法^[4-15]は、垂直エッジで囲まれた領域が車両であるという考え、低輝度の水平エッジを持つ画素が車両下影であるという考え、特に夜間シーンにおいてテールライトが車両の特徴として有効に働くという考え、車両背面の画素値には左右対称性が現れるという考えのもと 4 つの尤度特徴を設計している。最後に垂直エッジ、低輝度の水平エッジ、テールライトらしさ、左右対称性を重み付きで融合し、PF により追跡を行っている。この手法により追跡する領域は、車両背面全体ではなく、どのような車両でもおおまかに車両下影からテールライトまでをカバーできる領域となる。すなわち領域内における垂直エッジ、低輝度の水平エッジ、テールライトの距離、輝度値の対称性というのは、どのような車両にも成り立つものであるため、ある種普遍的な特徴を基に追跡することになる。そこで Chan らは、クラスタリング手法による粒子のグループ化をあわせて検討している。その後グループ毎に特化させた特徴により追跡するために、画像局所特徴量の一つ Haar-like 特徴量^[4-17]を教師あり機械学習手法の一つ AdaBoost^[4-18]により学習し、構築した識別器を用いて尤度の調整をしている。しかし、事前に構築した識別器を利用する手法は用意した学習パターンに依存するため、未知の環境にも比較的対応しやすいという追跡の利点を損ねる恐れがある。

4.1 節で述べたとおり、本論文では車両の追跡と車両下影の追跡を同時に行うことを目的に PF を採用するため、影らしさを表す尤度と車両らしさを表す尤度の二つを設計し、それらを融合した尤度に基づく追跡を検討する。この際、輝度値と周辺のテクスチャの値を追跡し、かつ車両背面の特徴量を評価する構造とすることで比較的個々の追跡対象に特化した特徴による追跡を可能とする。また、多くの追跡手法では追跡対象がある領域内におおよそ収まっていれば追跡成功となるが、本論文においては単眼距離推定への応用を前提とするため、車両下影座標の正確な追跡を実現する新しい手法として追跡手法を構築する。

4.3 Particle Filter による影らしさと車両らしさを考慮した車両下影

追跡の概要

表 4.1 に一般的な PF のアルゴリズムを示す。

表 4.1 Particle Filter アルゴリズム^[4-6]

Step 1 : Initialize

Set initial target region and initial coordinate for all particles

$$\{\mathbf{x}_{t=0}(n)\}_{n=1}^N.$$

Set $t = 1$ frame.

Step 2 : Prediction

Add normal random number to particles $\mathbf{x}_{t-1}(n)$, and make it new particles $\mathbf{x}_t(n)$.

Step 3 : Weighting particles

Calculate the particles weight from likelihood and normalize the weights sum to 1.

$$w_t(n) = p(\mathbf{y}_t | \mathbf{x}_t(n)) = LH_n$$

$$w_t(n) \leftarrow w_t(n) / \sum_{i=1}^N w_t(i)$$

Step 4 : Calculating the centroid of particles

Calculate the centroid of all particles and use it as the tracking result.

$$E[\mathbf{x}_t] = \sum_{n=1}^N w_t(n) \cdot \mathbf{x}_t(n)$$

Step 5 : Resampling

Resampling N particles according to the weight by sampling with replacement.

PF は、追跡対象としての尤もらしさを表す尤度から算出する重みに基づいて物体追跡を行うため、尤度特徴の設計が重要となる。また、尤度さえ適切に設計できれば状態空間を自由に設定できるため、柔軟性に富んだ追跡アルゴリズムである。

本論文で扱うある t フレームにおける粒子の状態 \mathbf{x}_t は、車両下影の中心座標 (x, y) とその上部領域(影の座標を中心とした車幅 w , 車高 h) で表す。本論文の追跡対象である車両は、車種によって車幅はあまり変化しないが、車高は様々なものが考えられる。ここで車両下影位置を表す追跡領域下端と比べると、追跡領域上端は追跡領域内に車両全体が収まってさえいれば、車両であるか背景であるかはそれほど重要ではない。また、推定する状態空間が大きくなると、より良い近似を得るためには多くの粒子が必要となるため、状態空間は小さい方

が計算コストの面で有利となる。以上を踏まえ、本論文では厳密に車幅や車高を追跡することはせず、車両全体が収まる正方形の車両スケール s として追跡することとした。図 4.2 に本論文で提案する、PF を応用した影らしさと車両らしさを考慮した車両下影追跡の概念図を示す。

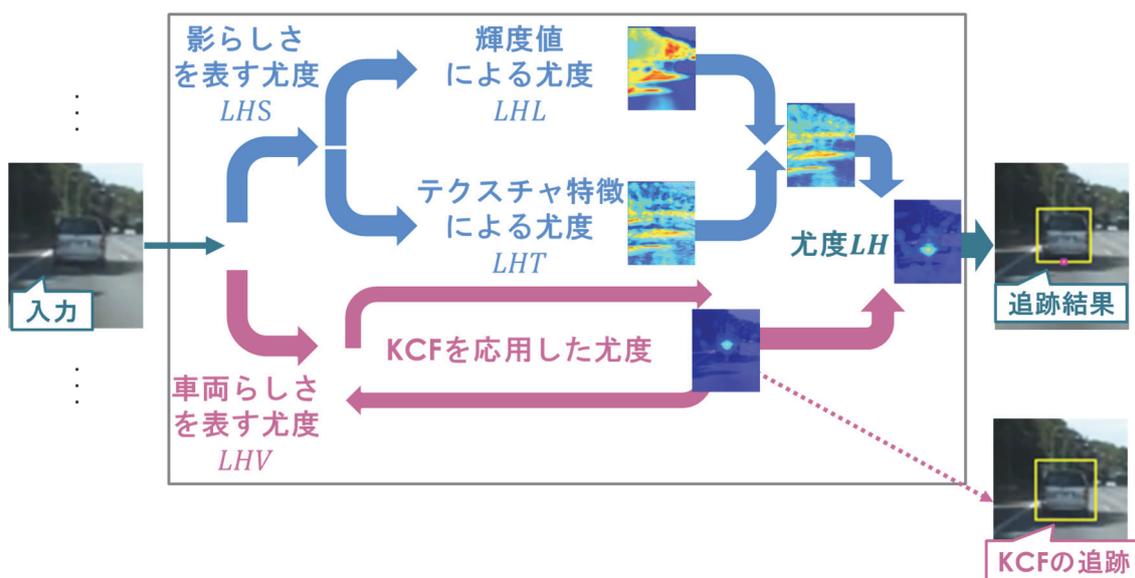


図 4.2 提案する車両下影追跡の概念図

影らしさを表す尤度 LHS は、各粒子が持つ座標の画素値を用いて算出する。影には輝度値が低いという特徴があるため、基本方針としてその座標における輝度値の低さを基に尤度 LHL を算出する。さらに、路面上には車両下影以外の影も存在することからテクスチャ特徴の尤度 LHT を融合し、車両下影位置で尤度 LHS が最も高くなるように設計する。

車両らしさを表す尤度 LHV は、車両スケール s で表す各粒子座標の上部領域の特徴を用いて算出する。本論文の目的は先行車両追跡であり、車両背面らしさを表すのに有効な特徴にエッジがある。エッジは物体の輪郭など、画素値(輝度値)の変化が急峻な位置に強く現れ、車両背面は車両ごとに特徴的なエッジを持つことが考えられるため基本方針として領域内のエッジ方向や強度を用い、物体領域を追跡する手法である KCF を応用して尤度 LHV を算出する。ここで車両下影と車両の追跡を同時に行うために、影らしさを表す尤度 LHS と車両らしさを表す尤度 LHV の融合を考える。この尤度特徴融合には、複数の尤度特徴を融合する方法^[4-7]の式(4.1)を用いる。

$$LH_n = (LHS_n)^{w_s} \cdot (LHV_n)^{w_v} \quad (4.1)$$

式中の n は n 個目の粒子を意味し、 w_s 及び w_v は、それぞれの尤度 LHS 、 LHV の重み ($w_s + w_v = 1$) である。

4.4 影らしさを表す尤度

影らしさを表す尤度 LHS は、輝度値の尤度 LHL と、テクスチャ特徴の尤度 LHT を融合する式(4.2)により求める。

$$(LHS_n)^{w_s} = (LHL_n)^{w_L} \cdot (LHT_n)^{w_T} \quad (4.2)$$

式中の n は n 個目の粒子を意味し、 w_L 及び w_T は、それぞれの尤度 LHL 、 LHT の重み ($w_L + w_T = w_s$) である。

以降の節では輝度値の尤度 LHL とテクスチャ特徴の尤度 LHT の算出方法について述べる。

4.4.1 前処理

RGB 表色系で表される画像を、輝度値 Y で表される輝度画像 (グレースケール) へ変換する。輝度変換には、NTSC 係数による加重平均の式(2.1)を用いる。

$$L = 0.299 \times R + 0.587 \times G + 0.114 \times B \quad \text{再掲(2.1)}$$

さらに、輝度画像から細かな雑音の影響を抑制するために平滑化を行う。平滑化には、輝度値の尤度算出時に 5×5 pixel、テクスチャ特徴の尤度算出時に 7×7 pixel のガウシアンフィルタをそれぞれ利用する。各フィルタサイズは経験的に得られた値であるが、輝度値算出時に大きなフィルタでぼかすと車両下影の低輝度のピークが路面の輝度値と混ざることが問題となるため大きいサイズは不適である。テクスチャ特徴算出時はフィルタサイズを大きくするとエッジは鈍るもののテクスチャは環境変動に対して安定するため、大きい方が有効に働くと考える。またテクスチャ特徴の尤度算出時、逆光などの影響で画像が全体的に暗い場合に画像のコントラストが下がり車両下影の特徴を適切に算出できない可能性がある。そこで、式(4.3)を用いたヒストグラム平坦化による画像補正を行う。

$$\hat{L}(x, y) = \frac{L_{\max}}{R} \sum_{i=0}^{L(x,y)} H(i) \quad (4.3)$$

式中の $L(x, y)$ は座標 (x, y) における入力画像の輝度値を表し、 L_{\max} は輝度値の最大値であり本論文では 255 となる。また、 $P(i)$ は累積輝度値分布を表し、 R は入力画像の画素数の総和を表す。

式(4.3)ではまず画像全体の累積輝度値分布 $H(i)$ を作成し、元の輝度値 $L(x, y)$ を累積輝度値分布 $H(i)$ に従う輝度値 $\hat{L}(x, y)$ へ変換することで一様な分布にし、画像のコントラストを改善する。図 4.3 にヒストグラム平坦化の例を示す。



(a) 影の影響で暗いシーン

(b) 逆光の影響で暗いシーン

図 4.3 ヒストグラム平坦化の例

4.4.2 輝度値による影らしさの尤度 LHL

影の特徴である輝度値の低さを尤度特徴とする際、画像中において車両下影よりも低い輝度値を持つ領域の存在が考えられる。そのため、単に輝度値が低いときの尤度を高くするだけでは追跡を誤る可能性がある。そこで、追跡位置とその周辺 M 点、計 $M + 1$ 点の輝度値を $L_{\text{track}}(m)$ として保持し、 $L_{\text{track}}(m)$ と n 個目の粒子に対する入力輝度値 $L_n(m)$ を比較することで輝度値の尤度 LHL_n を算出する。

具体的には $L_{\text{track}}(m)$ と $L_n(m)$ から式(4.4)に示す n 個目の粒子に対するユークリッド距離 DE_n を算出し、 DE_n を利用したガウス分布を表す式(4.5)により LHL_n を算出する。

$$DE_n = \sqrt{\sum_{m=0}^M (L_n(m) - L_{\text{track}}(m))^2} \quad (4.4)$$

$$LHL_n = \exp\left(-\frac{(DE_n)^2}{2(\sigma_L)^2}\right) \quad (4.5)$$

最後に、保持する輝度値 $L_{\text{track}}(m)$ は、単に現フレームで得た追跡位置の輝度値 $L_{\text{track}}^{\text{new}}(m)$ を用いて更新するのではなく、現フレームで保持していた輝度値 $L_{\text{track}}^{\text{prev}}(m)$ と更新率 γ_L を用いた加重和の式(4.6)により更新する。更新率 γ_L の決定方法については4.4.5項で述べる。

$$L_{\text{track}}(m) \leftarrow (1 - \gamma_L)L_{\text{track}}^{\text{prev}}(m) + \gamma_L L_{\text{track}}^{\text{new}}(m) \quad (m = 0, 1, \dots, M) \quad (4.6)$$

4.4.3 テクスチャ特徴による影らしさの尤度LHT

路面上に生じる建物等の影の尤度も高くなる問題があり、輝度値による尤度LHLのみによる追跡では不十分である。そこで、車両下影周辺には車両の一部が含まれるのに対し、路面上の影は周囲が一様に路面であるという違いがテクスチャに現れるとの考えのもと、テクスチャ特徴を利用した影らしさの尤度LHTを設計する。テクスチャ特徴には、3.3.1項で述べたとおり近傍画素との平均輝度差を考慮することで照明変動に頑健な性質を持つ、CLBP (Compound Local Binary Pattern) 特徴量^[4-19]を用いる。

CLBP 特徴量 \mathbf{c} の算出は、半径 R の円とその円上に位置する K 個の近傍画素の画素値 $L(k)$ と円の中心である着目画素値 $L(c)$ を用いて、式(3.2)により行う。

$$\mathbf{c} = \sum_{k=0}^{K-1} \left[(s(L(k), L(c)))_2 \ll 2p \right] \quad \text{再掲(3.2)}$$

$$s(L(k), L(c)) = \begin{cases} 00 & L(k) - L(c) < 0, |L(k) - L(c)| \leq K_{\text{avg}} \\ 01 & L(k) - L(c) < 0, |L(k) - L(c)| > K_{\text{avg}} \\ 10 & L(k) - L(c) \geq 0, |L(k) - L(c)| \leq K_{\text{avg}} \\ 11 & \text{otherwise} \end{cases}$$

式中の $()_2$ は2進数を、 \ll は左ビットシフトを意味する。また、式中の K_{avg} は、近傍における $L(k)$, $L(c)$ 間の差の平均値である。

本論文では、着目画素の周囲8近傍 ($R = 1, K = 8$) を利用して符号化する。8近傍について各2bitの符号化であるため、 n 個目の粒子が持つ座標に対し、CLBP特徴量により16bitの符号 $\mathbf{c}_n = \{c_{n_0}, c_{n_1}, \dots, c_{n_{15}}\}$ を生成することになる。尤度の算出は、輝度値の尤度と同様に

追跡位置とその周辺 M 点、計 $M + 1$ 点の CLBP 特徴量を $\mathbf{c}_{\text{track}}(m)$ として保持し、 n 個目の粒子に対する CLBP 特徴量 $\mathbf{c}_n(m) = \{c_{n_0}(m), c_{n_1}(m), \dots, c_{n_{15}}(m)\}$ と比較することで行う。具体的には $\mathbf{c}_{\text{track}}(m)$ と $\mathbf{c}_n(m)$ から式(4.7)に示す n 個目の粒子に対するハミング距離 DH_n を算出し、 DH_n を利用したガウス分布を表す式(4.8)によりテクスチャ特徴の尤度 LHT_n を算出する。

$$DH_n = \sum_{m=0}^M \left\{ \sum_{i=0}^{15} [(c_{n_i}(m) + c_{\text{track}_i}(m)) \bmod 2] \right\} \quad (4.7)$$

式中のmodは剰余を意味する。

$$LHT_n = \exp\left(-\frac{(DH_n)^2}{2(\sigma_T)^2}\right) \quad (4.8)$$

最後に、 $\mathbf{c}_{\text{track}}(m)$ の更新は、更新率 γ_T を累積したヒストグラムを作成することで行う。具体的には、新たな追跡位置の CLBP 特徴量 $\mathbf{c}_{\text{track}}^{\text{new}}(m)$ が得られるたびに、その特徴量が該当するヒストグラムの要素（ビン）に更新率 γ_T を加算し、加算した時点で更新率 γ_T の累積値が最大となるヒストグラムの要素を、 $\mathbf{c}_{\text{track}}(m)$ として利用する。更新率 γ_T の決定方法については4.4.5項で述べる。

4.4.4 尤度算出に用いる追跡位置周辺座標

4.4.2項、4.4.3項で述べたとおり、輝度値の尤度及びテクスチャ特徴の尤度ともに、表現能力向上のために追跡位置とその周辺 M 点の計 $M + 1$ 点の座標を利用して尤度算出を行う。本論文では、周辺 M 点としてまず車両下影の中心を捉えられるように追跡位置の周囲8近傍を利用する。さらに、どのような車両においても車両スケール s で表す領域の左右下端（追跡位置から $s/2$ 左右にシフトした位置）にはタイヤと路面の境界に関する特徴が現れると考え、領域の左右下端から内側にそれぞれ4画素ずつの8画素を加え、追跡位置と周辺 $M = 16$ 点、計17点の座標から尤度算出を行うこととした。

4.4.5 パラメータの動的決定

尤度 LHL 、 LHT ともに、更新率 γ とガウス分布における分散 σ^2 がパラメータとなる。輝度値、CLBP 特徴量のフレーム間での変化量は周囲の環境によって大きく異なるため、どのような環境においても適切な尤度算出ができるよう、各パラメータの動的決定法を検討する。

まず更新率 γ について、算出した尤度が高ければ、追跡対象の値の変化が少ないことを意味するため、大きく更新しても追跡への影響が少なく、逆に算出した尤度が小さければ、追跡対象の値の変化が大きいことを意味するため、小さく更新しなければ追跡が不安定になると考えられる。これを踏まえ、算出した尤度 LHL 、 LHT の値を基に更新率 γ_L, γ_T をそれぞれ決定することを考える。本論文における尤度は $[0,1]$ で算出するため、尤度を更新率としてそのまま用いると最小1フレームで保持する値が全く新しいものに更新される可能性がある。大きな更新が頻繁に繰り返されるのは、追跡精度の悪化に繋がると考えられるため、動画のフレームレート f を比例定数として（本論文では実験的に求めた値としてフレームレートの5倍とした）更新率が大きくなりすぎないように制限した式(4.9)を用いて、更新率を決定する。

$$\begin{aligned}\gamma_L &\propto \frac{LHL}{f} \\ \gamma_T &\propto \frac{LHT}{f}\end{aligned}\tag{4.9}$$

また、ガウス分布における分散 σ^2 については、尤度を表す式(4.5)、式(4.8)を変形して得られる式(4.10)を用いて算出する。

$$\begin{aligned}\sigma_L &= \frac{\sqrt{2}}{2} \sqrt{-\frac{DE^2}{\ln LHL}} \\ \sigma_T &= \frac{\sqrt{2}}{2} \sqrt{-\frac{DH^2}{\ln LHT}}\end{aligned}\tag{4.10}$$

式(4.10)において、ある距離に対応させる尤度値を与えれば所望の σ^2 を計算できる。本論文では平均より小さい距離を持つ粒子の尤度を際立たせるため、毎フレームで全粒子における距離の平均 \overline{DE} 、 \overline{DH} が尤度値0.4に対応するように分散 σ_L^2 、 σ_T^2 を算出し決定する。

4.5 車両らしさを表す尤度

車両らしさを表す尤度としては、2つのアプローチが考えられる。一つは、テンプレートマッチングなどの手法により単純な領域の類似度を算出し、尤度として用いる方法である。もう一つは、4.1節で述べた Tracking-by-detection の手法を適用し、追跡領域に合わせた識別器をオンライン学習するなどして、その識別器の出力となる追跡領域らしさを尤度に用いる方法である。本論文では高速かつ高精度な追跡の実現を目指し、相関フィルタ (Correlation Filter) を利用した Tracking-by-detection の手法の一つである KCF を、車両らしさを表す尤度 LHV として利用する。

4.5.1 KCF

KCF とは、相関フィルタを利用した追跡手法の一つである。相関フィルタを利用した手法は、相関計算を周波数領域における単純な要素同士の積で行えるため高速であることに加え、4.1節で述べたとおり KCF は高精度な物体追跡が可能のため、本論文の車両らしさを表す尤度 LHV として採用する。図 4.4 に KCF の概念図を示す。

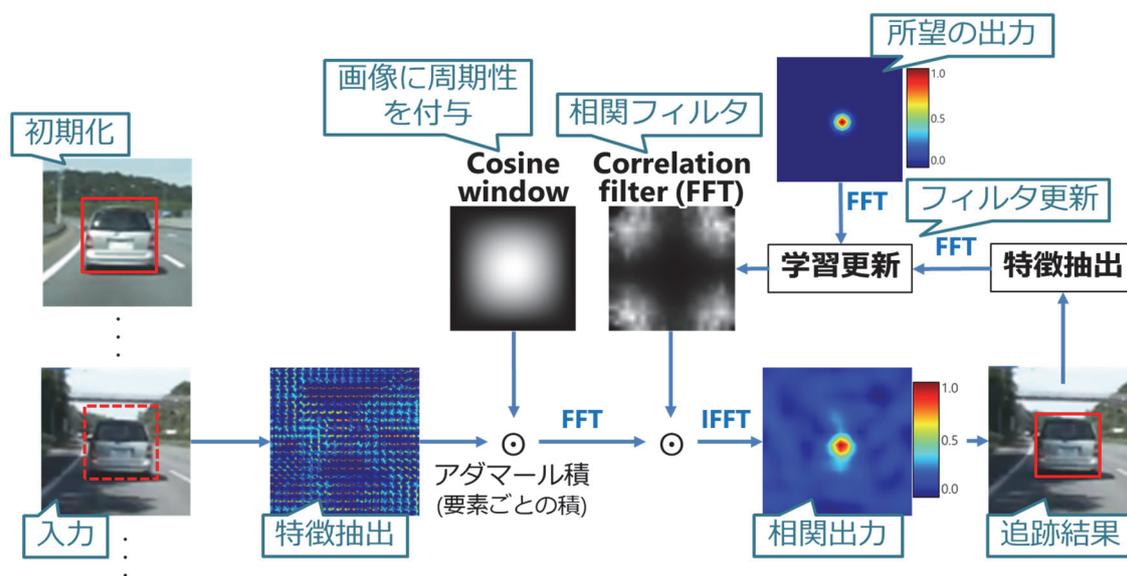


図 4.4 KCF の概念図

まず初期化として追跡の初期位置を基にエッジなどの特徴を抽出して相関フィルタを学習する。相関フィルタとは、端的には周波数領域に変換した入力とのスペクトル同士の乗算により対象の相関値を出力できるように学習したフィルタを指す。追跡時は入力画像から

学習時と同様の特徴を抽出し、画像に周期性を与えるために窓関数を適用してから相関フィルタを適用できるように FFT により周波数領域へ変換する。これとあらかじめ学習してある相関フィルタとのアダマール積をとり IFFT により逆変換することで画像空間領域における相関出力が得られ、この相関出力を基に追跡結果を得る。新しい追跡位置が得られたら、追跡対象の特徴の変化に追従できるように追跡領域の特徴を利用して相関フィルタを更新し、次のフレームへ移行する。これを繰り返すことで高速かつ高精度な物体追跡を行う。

(1) 相関フィルタの学習

与えられた学習サンプルと教師信号の対 (\mathbf{x}_i, y_i) をもとに、ある入力 \mathbf{z} に対する実数相関値を出力する回帰問題 $f(\mathbf{z}) = \mathbf{w}^T \mathbf{z}$ を学習する (T は転置を表す)。このために、式(4.11)に示す、損失関数として二乗誤差を与えるリッジ回帰により最小化問題を解くことを考える。このとき、周辺 (背景) の情報も併せて学習できるようにサンプルのサイズは追跡領域よりも大きいサイズ (本論文では追跡領域の 2.5 倍とした) で与える。また、簡単のため学習サンプルをベクトル $\mathbf{x} = [x_1, x_2, \dots, x_n]^T$ で表す。

$$\min_{\mathbf{w}} \left\{ \sum_i (f(\mathbf{x}_i) - y_i)^2 + \lambda \|\mathbf{w}\|^2 \right\} \quad (4.11)$$

式中の λ は、過学習抑制のための正則化項の係数であり、本論文では $\lambda = 0.0001$ とした。

リッジ回帰における最適解は式(4.12)で与えられる。

$$\mathbf{w} = \frac{X^T \mathbf{y}}{X^T X + \lambda I} \quad (4.12)$$

式中の X は各行にサンプル \mathbf{x}_i を持つ行列であり、 \mathbf{y} は各要素に教師データ y_i を持つベクトルである。また、 I は単位行列を表す。

式(4.12)におけるサンプル行列 X を、式(4.13)に示すように基準となる正解サンプル \mathbf{x} の巡回行列として与えると、巡回行列のトリック^[4-20]により周波数領域においてサンプル行列 X を対角化でき、式(4.12)は周波数領域におけるアダマール積 (要素ごとの積) を利用した式(4.14)のように表せる。

$$X = C(X) = \begin{pmatrix} x_1 & x_2 & x_3 & \cdots & x_n \\ x_n & x_1 & x_2 & \cdots & x_{n-1} \\ x_{n-1} & x_n & x_1 & \cdots & x_{n-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_2 & x_3 & x_4 & \cdots & x_1 \end{pmatrix} \quad (4.13)$$

$$\hat{\mathbf{w}} = \frac{\hat{\mathbf{x}}^* \odot \hat{\mathbf{y}}}{\hat{\mathbf{x}}^* \odot \hat{\mathbf{x}} + \lambda} \quad (4.14)$$

式中の \odot はアダマール積を、ハット記号 $\hat{}$ はベクトルのフーリエ変換を、 $*$ は複素共役を表す。

上述のことを踏まえ KCF では、データを高次の特徴空間 $\varphi(\mathbf{x})$ に写像することで強力な非線形回帰関数 $f(\mathbf{z})$ が得られるカーネルトリック^[4-21]を導入した、カーネルリッジ回帰を学習する。このときの回帰関数 $f(\mathbf{z})$ はカーネル関数 k とその係数 α を用いて $f(\mathbf{z}) = \mathbf{w}^T \mathbf{z} = \sum_i \alpha_i k(\mathbf{z}, \mathbf{x}_i)$ と表され、解くべき問題は \mathbf{w} の代わりに α を最適化する問題となる。このときの最適解は式(4.15)で与えられる^[4-22]。

$$\alpha = \frac{\mathbf{y}}{K + \lambda I} \quad (4.15)$$

式中の K は各要素に $K_{ij} = k(\mathbf{x}_i, \mathbf{x}_j)$ を持つカーネル行列であり、 α は各要素に係数 a_i を持つベクトルである。

ここで、サンプル行列 X を巡回行列としたうえでカーネル関数を適切に選べばカーネル行列 K は巡回行列となり、リッジ回帰のときと同様に周波数領域において対角化ができるため、 α のフーリエ変換 $\hat{\alpha}$ は式(4.16)のように表せる。

$$\hat{\alpha} = \frac{\hat{\mathbf{y}}}{\hat{\mathbf{k}}^{\mathbf{xx}} + \lambda} \quad (4.16)$$

ここで、 $\mathbf{k}^{\mathbf{xx}}$ はカーネル巡回行列 $K = C(\mathbf{k}^{\mathbf{xx}})$ の最初の行を意味し、カーネル関数 k によって決定される。

本論文では、カーネル関数 k に文献[4-13]の中でも言及されているガウスカーネル $k(\mathbf{x}, \mathbf{x}') = \exp(-1/\sigma^2 \|\mathbf{x} - \mathbf{x}'\|^2)$ を採用する。このときのカーネル相関 $\mathbf{k}^{\mathbf{xx}'}$ は式(4.17)のようになる。

$$\mathbf{k}^{\mathbf{x}\mathbf{x}'} = \exp\left(-\frac{1}{\sigma_{\text{kcf}}^2}(\|\mathbf{x}\|^2 + \|\mathbf{x}'\|^2 - 2\mathcal{F}^{-1}(\hat{\mathbf{x}}^* \odot \hat{\mathbf{x}}'))\right) \quad (4.17)$$

式中の \mathcal{F}^{-1} はフーリエ逆変換を表す。また、 σ_{kcf}^2 はガウスクーネルの広がり調整するパラメータであり、本論文では $\sigma_{\text{kcf}}^2 = 0.4$ とした。

このカーネル相関 $\mathbf{k}^{\mathbf{x}\mathbf{x}'}$ はノルムの計算と要素ごとの積のみを必要とするため、RGB など、マルチチャネルデータ $\mathbf{x} = [\mathbf{x}_1, \dots, \mathbf{x}_U]$ を対象とする場合の拡張は、式(4.18)に示すように周波数領域における加算によって実現できる。

$$\mathbf{k}^{\mathbf{x}\mathbf{x}'} = \exp\left(-\frac{1}{\sigma_{\text{kcf}}^2}\left(\|\mathbf{x}\|^2 + \|\mathbf{x}'\|^2 - 2\mathcal{F}^{-1}\left(\sum_u \hat{\mathbf{x}}_u^* \odot \hat{\mathbf{x}}'_u\right)\right)\right) \quad (4.18)$$

本論文では、マルチチャネルデータとして局所領域におけるエッジ方向ヒストグラムを正規化して特徴量とする HOG 特徴量^[4-23]を採用し、HOG 特徴量の各次元をチャネルとして持つデータを用いて、フィルタの学習及び追跡を行う。なお HOG 特徴量は、 $0 \sim \pi$ [rad]を9方向で量子化し算出する。

(2) 相関フィルタを利用した検出に基づく追跡

前のフレームにおける追跡位置を中心とする入力 \mathbf{z} に対して式(4.19)により相関計算を行うことで最も高い相関値を出力する位置を検出し、新たな追跡位置とする。

$$\mathbf{f}(\mathbf{z}) = \sum_i \alpha_i k(\mathbf{z}, \mathbf{x}_i) = \{C(\mathbf{k}^{\mathbf{z}\mathbf{z}})\}^T \boldsymbol{\alpha} = \mathcal{F}^{-1}(\hat{\mathbf{k}}^{\mathbf{z}\mathbf{z}} \odot \hat{\boldsymbol{\alpha}}) \quad (4.19)$$

また、マルチスケール追跡に対応するため倍率 b を設定し、KCF で追跡中のスケールサイズ s_{kcf} を基にした入力 \mathbf{z} 及び、 b 倍、 $1/b$ 倍に拡大、縮小した計3つのスケールにおいて相関計算を行い、最も高い相関値を出力するスケールで s_{kcf} を更新する^[4-24]。これにより、基本的には KCF のみでスケールの追跡まで行え、PF で予測する状態空間から車両スケール \mathbf{s} を除外できることになり、少ない粒子数でより安定した追跡が実現可能になる。

(3) 相関フィルタの更新

KCF における追跡で必要となるのは式(4.19)で利用する、係数 α と基準となるサンプル \mathbf{x} である。いずれも学習率 ε を用いた加重和の式(4.20)を用いて更新する。

$$\begin{aligned}\alpha &\leftarrow (1 - \varepsilon)\alpha + \varepsilon\alpha^{\text{new}} \\ \mathbf{x} &\leftarrow (1 - \varepsilon)\mathbf{x} + \varepsilon\mathbf{x}^{\text{new}}\end{aligned}\tag{4.20}$$

4.5.2 車両らしさを表す尤度としての応用

KCF は車両の中央を基準とした[0,1]の相関を出力するため、この相関出力を、車両らしさを表す尤度特徴 LHV として利用する。このとき、KCF による尤度 LHV は車両中央にピークを持つため、尤度融合の際には車両中央から車両下影までの距離、すなわち追跡中の車両スケールの半分の値を下方にずらして利用する。尤度の算出例を図 4.5 に示す。

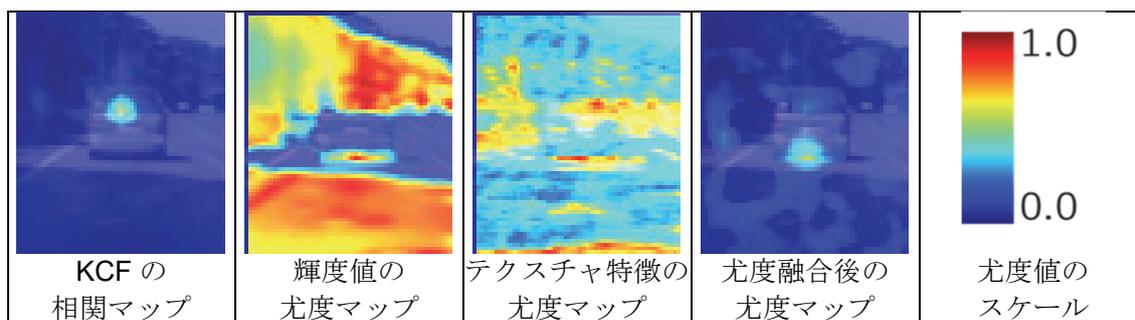


図 4.5 尤度算出例

4.5.3 KCF 及び Particle Filter を用いたスケール補正

KCF は車両の中心座標を精度良く捉え、PF による車両下影追跡は路面に接地する車両領域下端の座標を精度良く捉えることができる。これを利用し、KCF で追跡中の車両スケール s_{kcf} を補正して最終的な車両スケール s を決定する。具体的には、KCF の追跡座標（車両中心）と PF の追跡座標（車両下端）の距離を 2 倍したものを新たな車両スケール候補 s' とし、 s_{kcf} と重み係数 β を利用した式(4.21)によりスケール補正を行う。

$$s = (1 - \beta)s_{\text{kcf}} + \beta s'\tag{4.21}$$

なお、KCF で追跡中の車両スケール s_{kcf} は、KCF による追跡の安定性にも関わるため $s_{\text{kcf}} = s$ として直接更新することはせず、マルチスケール対応のための倍率 b を、車両スケール候補 s' を利用して式(4.22)により動的に更新することで、 s_{kcf} が実際に追跡中の車両スケール s に近づくようにする。

$$b = \begin{cases} \frac{s'}{s} & s' > s \\ \frac{s}{s'} & \text{otherwise} \end{cases} \quad (4.22)$$

4.5.4 KCF 及び Particle Filter を用いた追跡位置補正

KCF による車両らしさは領域中心にピークを持つが、車両下影が横に広がって存在することから影らしさも横に拡がりやすい特徴があり、4.3 節の表 4.1 に示すように全粒子の重心位置 $(x_{\text{cog}}, y_{\text{cog}})$ を追跡位置 $(x_{\text{track}}, y_{\text{track}})$ とすると、尤度融合した際に x 座標で安定しない問題がある。そこで、尤度が最大となる位置 $(x_{\text{max}}, y_{\text{max}})$ と重み係数 δ_x, δ_y を利用して式(4.23)により補正する。

$$\begin{aligned} x_{\text{track}} &= (1 - \delta_x)x_{\text{cog}} + \delta_x x_{\text{max}} \\ y_{\text{track}} &= (1 - \delta_y)y_{\text{cog}} + \delta_y y_{\text{max}} \end{aligned} \quad (4.23)$$

4.6 車両追跡実験

Particle Filter による影らしさと車両らしさを考慮した車両下影追跡の有効性を検証するために提案手法のほか3つの手法を用いて比較実験を行う。

4.6.1 実験条件

実験の諸条件を以下に示す。

○PC の仕様

- CPU Intel Core i7 6800K 3.40GHz
- RAM 32GB
- OS Windows 10 64bit

○実験シーン（動画）：QVGA（320×240 pixel），30 fps

実験には以下のシーンを使用した。なお、高速道路昼晴天シーン及び一般道夜雨天シーンは第2章、第3章で使用したものと同様のシーンである。

- 高速道路 昼 晴天 1 シーン 1,000 frames
- 一般道 夜 雨天 1 シーン 1,000 frames
- 一般道 夕 逆光 1 シーン 1,000 frames

○比較手法

- ・ KCF Kernelized Correlation Filter
- ・ PF-LHL LHL(Luminance)とLHVを融合した Particle Filter
- ・ PF-LHT LHT(CLBP)とLHVを融合した Particle Filter
- ・ 提案手法 LHSとLHVを融合した Particle Filter

○パラメータ

- ・ 粒子数 $N = 4000$
- ・ 尤度融合重み $w_L = 0.15, w_T = 0.35, w_V = 0.5$
- ・ KCF 更新率 $\varepsilon = 0.005$
- ・ スケール補正用重み係数 $\beta = 0.4$
- ・ 追跡位置補正用重み係数 $\delta_x = 0.9, \delta_y = 0.5$

○評価方法

追跡性能評価のための評価値に、3.5節でも使用した式(3.28)で定義される Jaccard 係数を用いる。2つ目の評価基準としてx座標, y座標, スケールそれぞれの追跡誤り画素を用いる。

4.6.2 実験結果及び考察

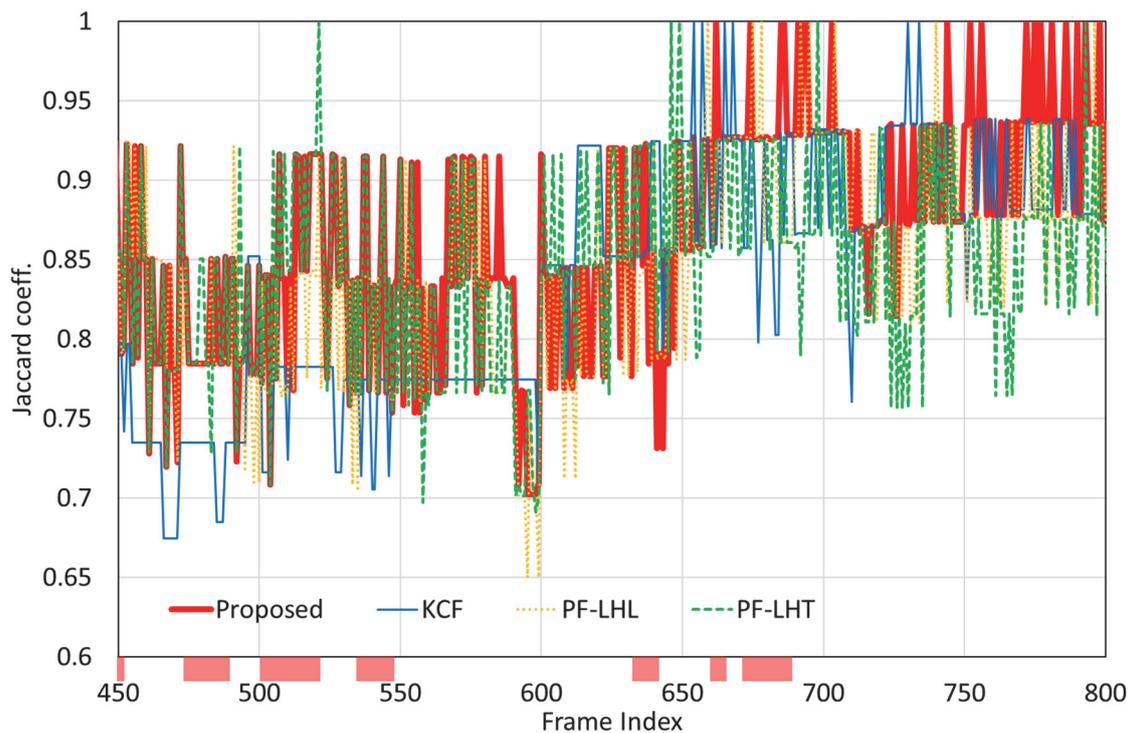
追跡結果の画像例とあわせて示す曲線は、追跡位置のx座標で固定し、y方向に走査した時の輝度値[0, 255] (横軸が輝度値, 縦軸が画像に対応したy座標)を表している。

(1) 高速道路昼晴天シーンにおける実験結果の比較

実験には、建物等の影が繰り返し現れるシーンを利用した。表 4.2 に評価値及び追跡誤り画素をシーン毎にまとめたものを示す。また図 4.6 に 350frame 分抜き出した評価曲線を、図 4.7 に追跡結果の画像例を示す。図 4.6 に示す評価曲線を見ると、いずれの手法も評価値 0.86 付近で良好に推移している。また表 4.2 の結果より、KCF は車両中心を精度良く捉えることができ、x 座標, y 座標の平均追跡誤りが 1pixel 未満となったことが確認できる。これに対し提案手法では、4.5.4 項でも述べたように影らしさが横に広がることから x 座標の追跡誤りが増加したものの y 座標及びスケールの追跡誤りを 4 手法中最小にできた。これは、図 4.7(a)の輝度値曲線に示すように影の中においても車両下影位置に低輝度のピークが現れるため、図 4.7(b)の尤度マップに示すように、特にテクスチャの尤度LHTが貢献し、車両下影位置の尤度を高くできたことが要因である。さらに車両らしさの尤度LHVと融合することで、正しく車両下影位置付近のみ尤度を高くでき、追跡誤りの低下につながった。

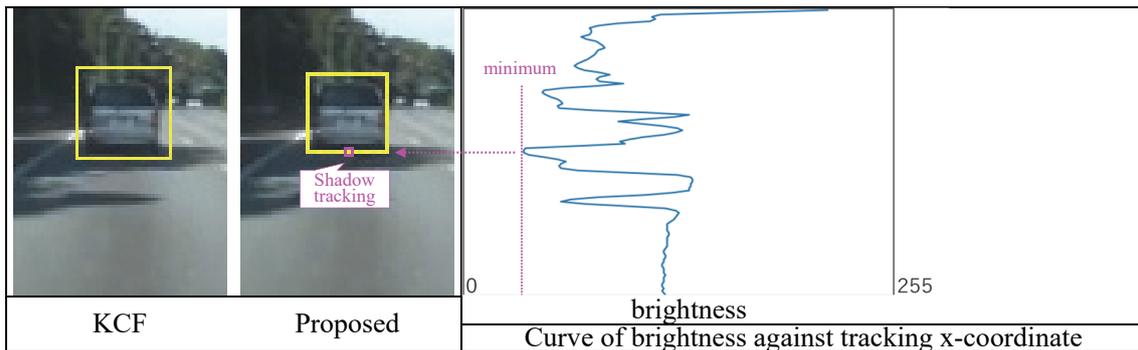
表 4.2 高速道路昼晴天シーンの実験結果

	KCF	PF-LHL	PF-LHT	提案手法
平均評価値 (Jaccard 係数)	0.86	0.87	0.87	0.88
最小評価値 (Jaccard 係数)	0.67	0.65	0.68	0.68
平均 x 座標誤差 [pixel]	0.52	1.13	1.24	1.15
平均 y 座標誤差 [pixel]	0.63	0.73	0.56	0.47
平均スケール誤差 [pixel]	1.94	0.95	0.94	0.89
最大 x 座標誤差 [pixel]	3	4	4	4
最大 y 座標誤差 [pixel]	4	3	2	3
最大スケール誤差 [pixel]	5	5	5	4
平均処理時間 [ms]	7.56	8.99	9.95	10.6

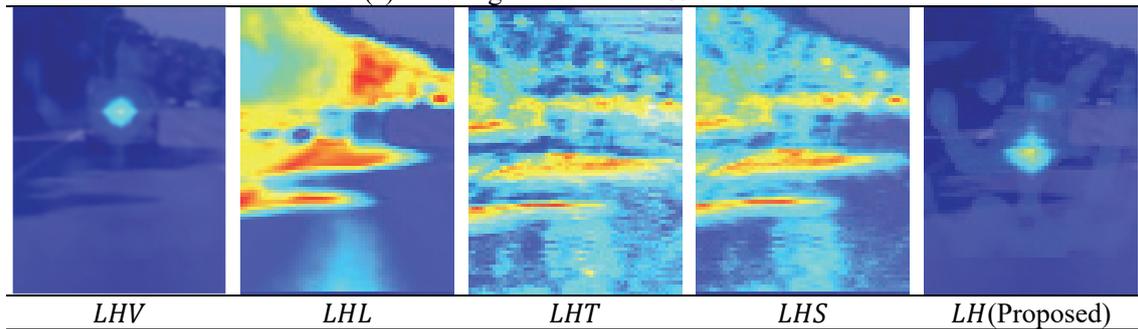


横軸の赤で示す区間：車両下影と森林の影が重なるフレーム

図 4.6 高速道路昼晴天シーンの評価曲線



(a) Tracking result of the 483th frame



(b) Likelihood map of the 483th frame

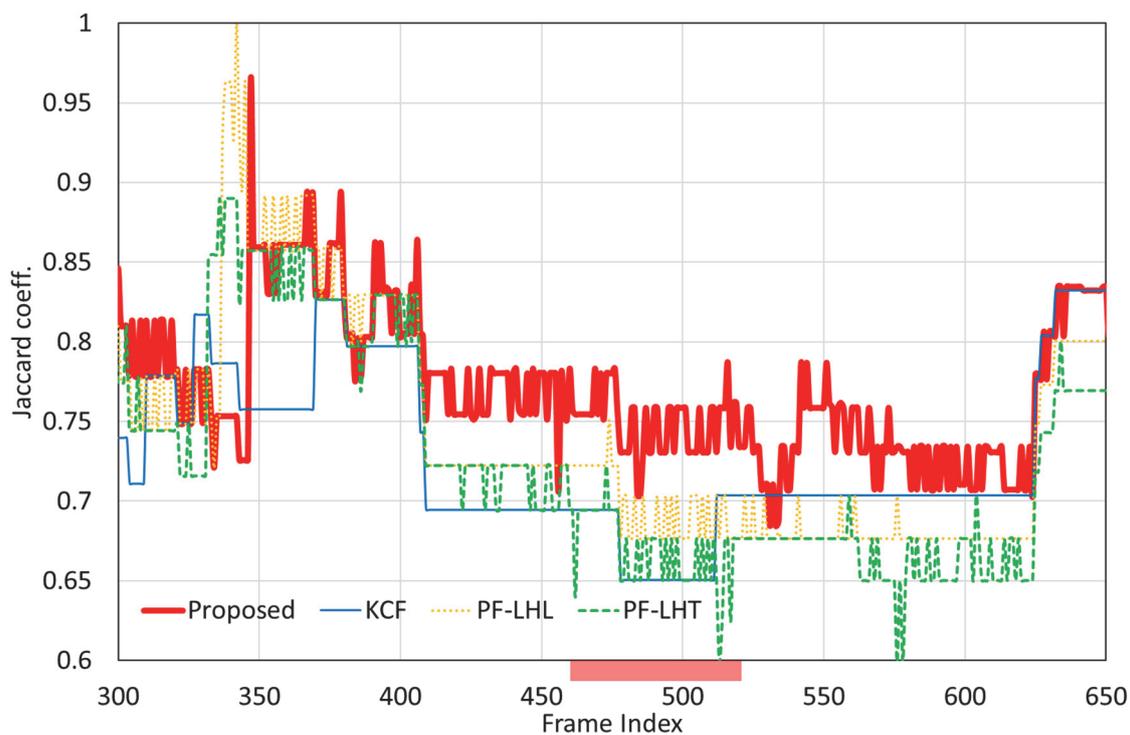
図 4.7 高速道路昼晴天シーンの追跡結果例

(2) 一般道夜雨天シーンにおける実験結果の比較

実験には、雨であることに加えて先行車両がブレーキを踏み大きな照明変動が生じるシーンを利用した。表 4.3 に評価値及び追跡誤り画素をシーン毎にまとめたものを示す。また、図 4.8 に 350frame 分抜き出した評価曲線を、図 4.9 に追跡結果の画像例を示す。表 4.3 に示すように、提案手法では y 座標及びスケールの平均追跡誤りを 4 手法中最小とし、特に y 座標追跡誤りについては KCF の半分以下とすることができた。図 4.8 に示す評価曲線を見ると、KCF では 412frame 以降で評価値が 0.1 以上低くなって推移している。これは、先行車両がブレーキを踏み大きな照明変動が起きたことに加え、車両が近づくことによる急激なスケール変化に追従できず、図 4.9(a)に示すように追跡領域が車体部分に集中したことが原因である。これに対し提案手法では、夜間かつ大きな照明変動下においても図 4.9(a)の輝度値曲線に示すように車両下影位置に低輝度のピークが現れているため、影らしさを表す尤度 LHS を用いることで図 4.9(b)に示すように車両下影位置の尤度を高くすることができた。さらに車両下影位置を利用したスケール補正により、車両領域も精度良く追跡できた。

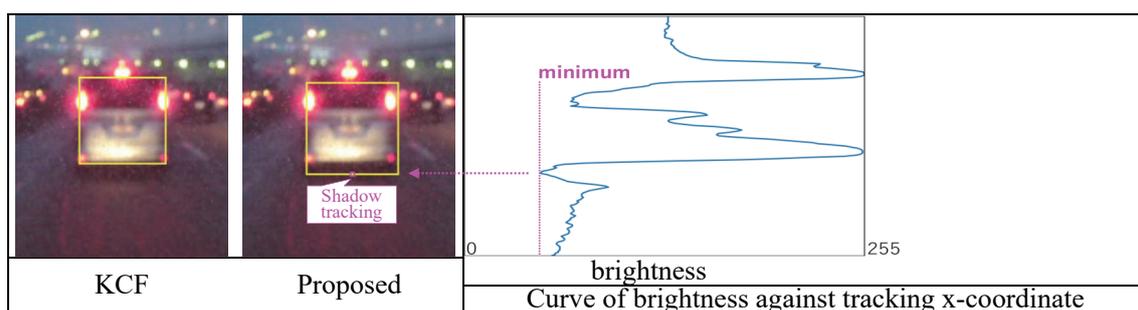
表 4.3 一般道夜雨天シーンの実験結果

	KCF	PF-LHL	PF-LHT	提案手法
平均評価値 (Jaccard 係数)	0.78	0.80	0.78	0.82
最小評価値 (Jaccard 係数)	0.65	0.66	0.60	0.62
平均 x 座標誤差 [pixel]	0.89	0.88	0.99	0.95
平均 y 座標誤差 [pixel]	2.44	1.22	1.21	1.15
平均スケール誤差 [pixel]	5.80	4.74	5.59	3.85
最大 x 座標誤差 [pixel]	4	3	4	5
最大 y 座標誤差 [pixel]	7	4	6	6
最大スケール誤差 [pixel]	12	11	14	10
平均処理時間 [ms]	8.48	10.2	10.1	11.3

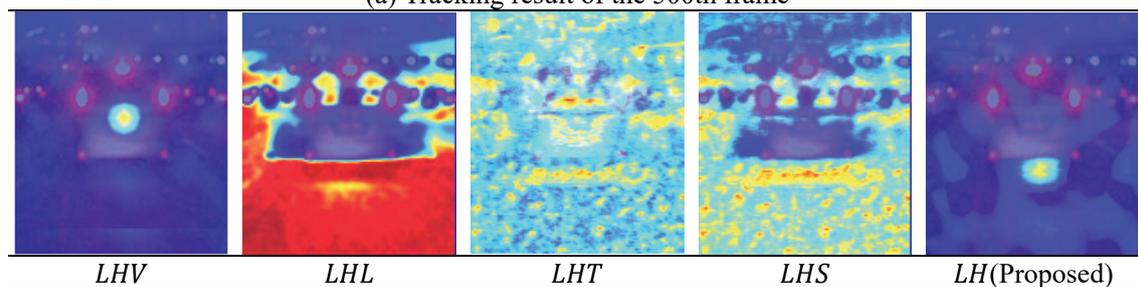


横軸の赤で示す区間：先行車両がブレーキを踏むフレーム

図 4.8 一般道夜雨天シーンの評価曲線



(a) Tracking result of the 500th frame



(b) Likelihood map of the 500th frame

図 4.9 一般道夜雨天シーンの追跡結果例

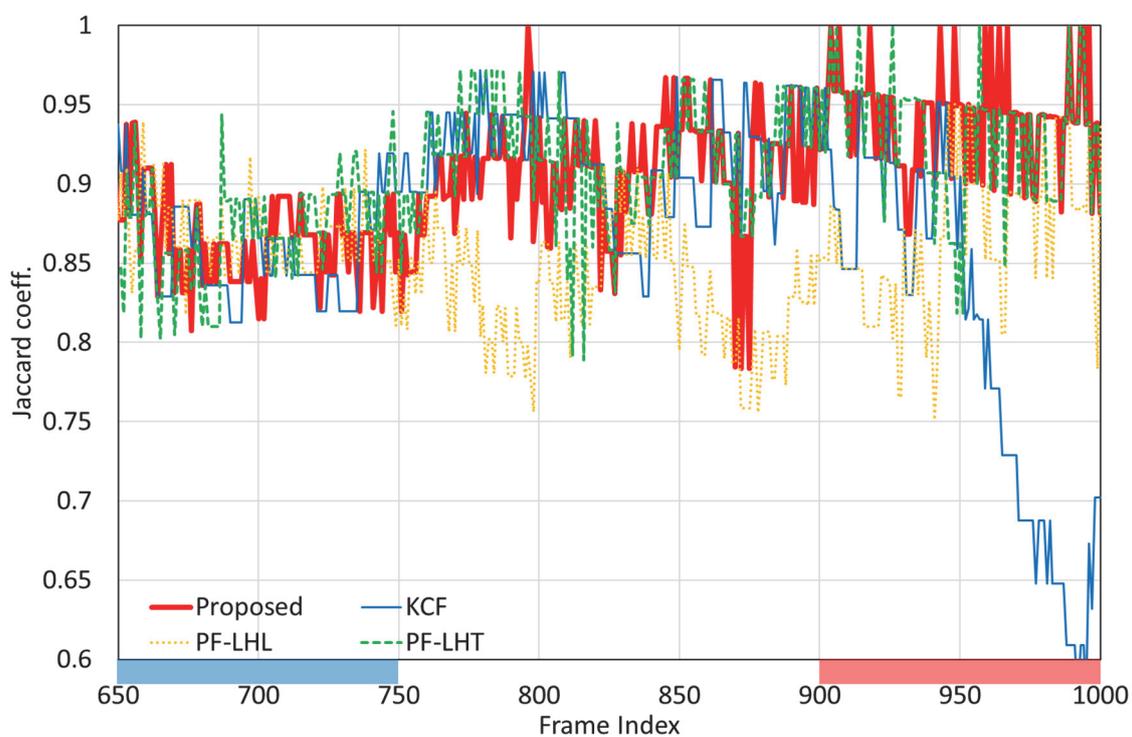
(3) 一般道夕方逆光シーンにおける実験結果の比較

実験には、逆光であることに加え、先行車両の加減速により大きなスケール変化が生じるシーンを利用した。表 4.4 に評価値及び追跡誤り画素をシーン毎にまとめたものを示す。また、図 4.10 に 350frame 分抜き出した評価曲線を、図 4.11 に追跡結果の画像例を示す。

表 4.4 に示すように、逆光シーンにおいても、提案手法では y 座標及びスケールの平均追跡誤りを 4 手法中最小とし、特に y 座標追跡誤りについて KCF の約半分とすることができた。図 4.10 に示す評価曲線を見ると、KCF では 950frame 以降で評価値が急激に悪化した。これは、800frame 付近から 1000frame にかけて先行車両のスケールが 70×70 pixel 程度から 30×30 pixel 程度まで大きく変化したことに追従しきれなかったことが原因である。これに対し提案手法では、図 4.11(a)の輝度値曲線に示すように逆光においても車両下影位置に低輝度のピークが現れていることに加え、僅かに生じる路面とタイヤ部分の特徴等を捉えることで図 4.11(b)に示すように車両下影位置の尤度を高くすることができた。これにより車両下影位置を頑健に捉えることができ、車両下影位置を利用したスケール補正により、車両領域も精度良く追跡できた。

表 4.4 一般道夕方逆光シーンの実験結果

	KCF	PF-LHL	PF-LHT	提案手法
平均評価値 (Jaccard 係数)	0.88	0.88	0.90	0.90
最小評価値 (Jaccard 係数)	0.57	0.73	0.74	0.76
平均 x 座標誤差 [pixel]	1.30	1.26	0.95	1.03
平均 y 座標誤差 [pixel]	1.62	2.23	1.16	0.84
平均スケール誤差 [pixel]	2.77	2.31	2.75	2.29
最大 x 座標誤差 [pixel]	4	4	5	5
最大 y 座標誤差 [pixel]	5	9	7	7
最大スケール誤差 [pixel]	10	11	9	8
平均処理時間 [ms]	8.60	9.86	11.0	10.8



横軸の青で示す区間：先行車両が減速するフレーム

横軸の赤で示す区間：先行車両が加速するフレーム

図 4.10 一般道夕方逆光シーンにおける評価曲線

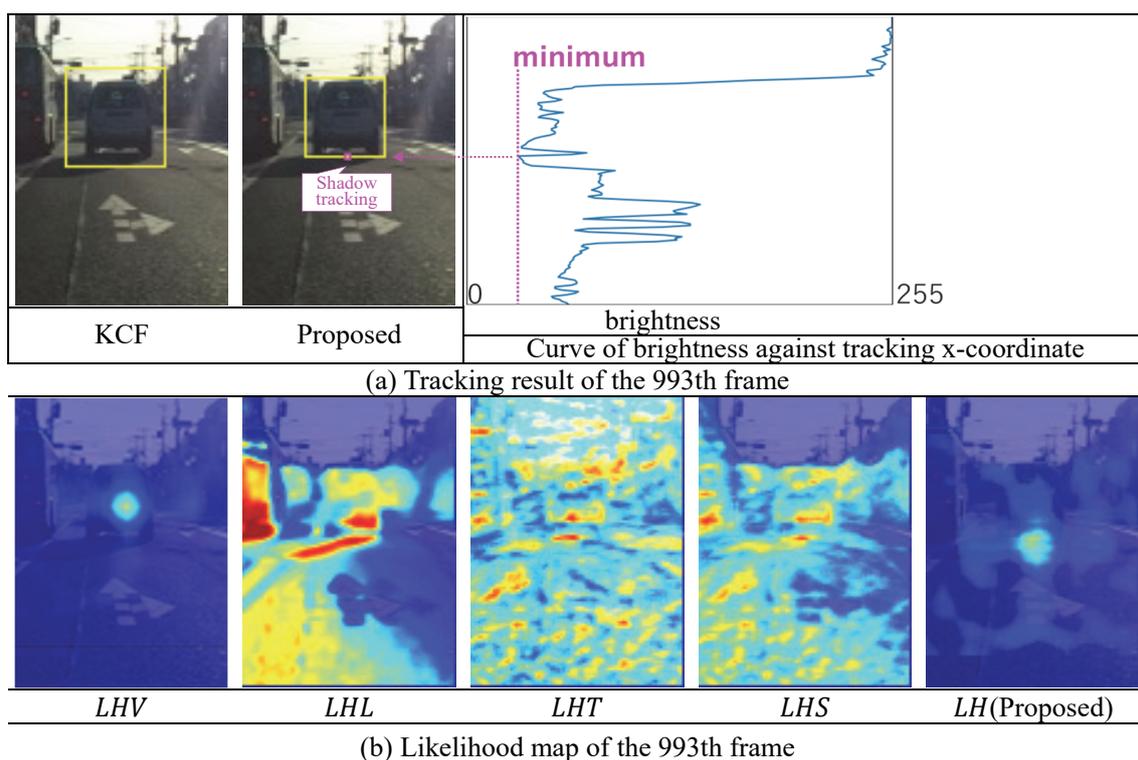


図 4.11 一般道夕方逆光シーンにおける追跡結果例

(4) 平均処理時間の比較

比較手法である KCF は 3 シーンの平均で処理時間約 8.21ms と高速な処理を実現できている。提案手法は KCF には劣るものの粒子数 4000 の設定においても約 2.7ms の処理時間増で抑えつつ、夜間、雨天、逆光といった環境における車両下影追跡精度の向上を実現できた。

4.6.3 安全運転支援システムとしての評価

4.6.2 項に示した実験結果より、高速道路昼晴天シーンにおいては従来手法である KCF、提案手法ともに平均約 1pixel の y 座標追跡誤りとなるが、一般道夜雨天及び一般道夕方逆光においては KCF で平均約 2pixel の y 座標追跡誤りに対し、提案手法では平均約 1pixel の y 座標追跡誤りに抑えられている。

AEBS の協定規則 (UN-R152) ^[4-25] による対車両の試験では、静止する車両に速度 40km/h で衝突しないこと、速度 20km/h で先行する車両に速度 60km/h で衝突しないこと、すなわち相対速度 40km/h で先行車両に衝突しないことが求められている。また、衝突回避のための緊急制動に対して警報に対する反応時間である 0.8 秒前までに警報することが要件としてある。第 3 期 ASV 推進計画で策定された前方障害物衝突軽減制動装置の実用化指針におい

て自動制御の作動タイミングは衝突時間 (TTC) により規定されており、制動回避限界 (衝突を制動により回避できる限界の TTC) と操舵回避限界 (衝突を操舵により回避できる限界の TTC) によって決定される衝突判断ラインが基本となる。これをドライバの過信を招かない範囲で拡大可能な領域として衝突可能性判断ラインが設定された。これは通常の走行時にドライバが回避操作を開始する時間でもある。よって、前方車両衝突警報システムは衝突可能性判断ラインよりも (警報に対する反応時間である) 0.8 秒前に動作できることが要件となる。

乗用車における衝突可能性判断ラインはおおよそ 1.4 秒とされているため警報のタイミングは衝突の 2.1 秒前となる。相対速度 40km/h の場合、TTC が 2.1 秒の車間距離は約 23.3m であるため、警報システムとして基準を満たすためには車間距離 23m 付近に位置する先行車両を適切に検出できる必要がある。本実験環境では、QVGA (320×240pixel) の解像度を用いており、カメラの垂直画角を 60° 、設置高さを 1.6m と仮定すると、式(1.2)より 1pixel の y 座標追跡誤りの場合は車間距離の推定誤差約 2.67m、2pixel の y 座標追跡誤りの場合は車間距離の推定誤差約 4.79m となる。これを TTC で考えると、車間距離約 23.3m の TTC 約 2.1 秒に対して 1pixel の y 座標追跡誤りの場合は約 0.24 秒の誤差、2pixel の y 座標追跡誤りの場合は約 0.43 秒の誤差となる。

一般的な反応時間 0.8 に対して 1pixel 分の誤差を含んだ場合の 0.56 秒は短い時間となるが、衝突可能性判断ラインが衝突までに少し余裕を見ている時間であるため、最終的な衝突は回避できる可能性が高い。2pixel 分の誤差を含んだ場合には 0.37 秒まで短くなり、この状況における 0.2 秒の差は非常に大きい。よって提案手法による車両下影追跡は従来の物体追跡手法よりも、安全運転支援のための前方車両衝突警報システムへの応用が期待できる。

4.7 まとめ

本章の特徴は、一般的な物体追跡のアプローチでは難しい車両下影の追跡を、影らしさと車両らしさを同時に追跡することで実現した点にある。具体的には PF のフレームワークを利用して、輝度及びテクスチャによる影らしさと KCF による車両らしさを組み合わせた車両下影追跡手法を提案した。高速道路昼晴天シーン、一般道夜雨天シーン及び夕方逆光シーンの動画像を用いた実験により、提案手法はすべてのシーンにおいて、その他の 3 手法よりも平均評価値、 y 座標及びスケール追跡誤りで最良の結果を得ることができた。実験結果により、影抽出が困難と考えられる夜間、雨天、逆光といった環境にも対応できることを示した。

文 献

- [4-1] K. Higashi, S. Fukui, Y. Iwahori, Y. Adachi, and M. K. Bhuyan : “New Feature for Shadow Detection by Combination of Two Features Robust to Illumination Changes”, *Journal of Procedia Computer Science*, Vol.96, pp.896-903 (2016)
- [4-2] J. B. Huang and C. S. Chen: “Moving cast shadow detection using physics-based features”, in *Proc. IEEE Conf. on Computer Vision and Pattern Recognition(CVPR)*, pp.2310-2317 (2009)
- [4-3] C. Tomasi and T. Kanade: “Shape and motion from image streams under orthography: a factorization method”, *International Journal of Computer Vision*, Vol.9, No.2, pp.137-154 (1992)
- [4-4] D. Comaniciu, V. Ramesh and P. Meer: “Real-time tracking of non-rigid objects using mean shift”, in *Proc. IEEE Conf. on Computer Vision and Pattern Recognition(CVPR)*, Vol.2, pp.142-149 (2000)
- [4-5] G. Bradski: “Computer Vision Face Tracking For Use in a Perceptual User Interface”, *Intel Technology Journal*, Q2, pp.214-219 (1998)

- [4-6] M. Isard and A. Blake: "CONDENSATION-conditional density propagation for visual tracking", *International Journal of Computer Vision* , Vol.29, No.1, pp.5-28 (1998)
- [4-7] P. Brasnett, L. Mihaylova, D. Bull, and N. Canagarajah: "Sequential Monte Carlo tracking by fusing multiple cues in video sequences", *Journal of Image and Vision Computing*, Vol.25, Issue.8, pp.1217-1227 (2007)
- [4-8] H. Grabner, M. Grabner, and H. Bischof: "Real-time Tracking via On-line Boosting", *Proc. in British Machine Vision Conference(BMVC) 2006*, Vol. 1, pp. 47-56 (2006)
- [4-9] B. Babenko, M. H. Yang, and S. Belongie: "Visual Tracking with Online Multiple Instance Learning", in *Proc. IEEE Conf. on Computer Vision and Pattern Recognition(CVPR)*, pp.983-990 (2009)
- [4-10] Z. Kalal, K. Mikolajczyk, and J. Matas: "Tracking-Learning-Detection", *IEEE Trans. on Pattern Analysis and Machine Intelligence(PAMI)*, Vol. 34, No. 7, pp.1409-1422 (2012)
- [4-11] D. S. Bolme, B. A. Draper and Y. M. Lui: "Visual Object Tracking using Adaptive Correlation Filters", in *Proc. IEEE Conf. on Computer Vision and Pattern Recognition(CVPR)*, pp.2544-2550 (2010)
- [4-12] J. F. Henriques, R. Caseiro, P. Martins, and J. Batista: "Exploiting the circulant structure of tracking-by-detection with kernels", in *Proc. European Conference on Computer Vision (ECCV)*, pp. 702-715 (2012).
- [4-13] J. F. Henriques, R. Caseiro, P. Martins, and J. Batista: "High-Speed Tracking with Kernelized Correlation Filter", *IEEE Trans. on PAMI*, Vol. 37, No. 3, pp. 583-596 (2015)
- [4-14] S. Wan, S. Kodagoda and S. Sehestedt: "Multiple Cue Based Vehicle Detection and Tracking for Road Safety", *Proc. of the 8th International Conference on Intelligent Technologies (InTech-07)*, pp. 340-345 (2007)
- [4-15] Y.-M. Chan, S.-S. Huang, L.-C. Fu, P.-Y. Hsiao: "Vehicle detection and tracking under various lighting conditions using a particle filter", *Journal of IET Intelligent Transport Systems*, Vol.6, issue 1, pp.1-8 (2012)

- [4-16] 関 弘翔・泉 隆・細野裕行：「Particle Filterによる影らしさと車両らしさを考慮した先行車両追跡」, 電気学会論文誌A, Vol. 139, No. 11, pp.585-595 (2019)
- [4-17] P. Viola and M. Jones: “Rapid object detection using a boosted cascade of simple features”, in Proc. IEEE Conf. on Computer Vision and Pattern Recognition(CVPR), Vol. 1, pp.511-518 (2001)
- [4-18] Y. Freund and R. E. Schapire: “A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting”, Computational Learning Theory -Second European Conference (EuroCOLT'95), Vol.904, pp.23-37 (1995)
- [4-19] F. Ahmed, E. Hossain, A.S.M. Hossain, and ASM. Shihavudd: “Compound Local Binary Pattern (CLBP) for Facial Expression Recognition”, in Proc. IEEE International Symposium on Computational Intelligence and Informatics(CINTI), pp. 391-395 (2011)
- [4-20] R. M. Gray: “Toeplitz and Circulant Matrices: A Review”, Foundations and Trends® in Communications and Information Theory, Vol. 2, No. 3, pp 155-239 (2006)
- [4-21] B. Schölkopf and A. Smola: “Learning with kernels: Support vector machines, regularization, optimization, and beyond”, MIT Press (2002)
- [4-22] R. Rifkin, G. Yeo, and T. Poggio: “Regularized least-squares classification”, Nato Science Series Sub Series III Computer and Systems Science, Vol. 190, pp. 131-154 (2003)
- [4-23] N. Dalal and B. Triggs: “Histograms of Oriented Gradients for Human Detection”, in Proc. IEEE Conf. on Computer Vision and Pattern Recognition(CVPR), Vol.1, pp.886-893 (2005)
- [4-24] Y. Li and J. Zhu: “A Scale Adaptive Kernel Correlation Filter Tracker with Feature Integration”, in Proc. European Conference on Computer Vision(ECCV), pp. 254-265 (2015)
- [4-25] UN Regulation No.152: “Uniform provisions concerning the approval of motor vehicles with regard to the Advanced Emergency Braking System (AEBS) for M1 and N1 vehicles” (2020)

第5章 結論

ITS の開発分野の 1 つである安全運転支援システムの基盤技術として、車載単眼カメラを利用した手法の利点に着目し、車載単眼カメラとコンピュータを利用した画像処理による先行車両検出システムとすることで、自動車への追加設置が容易なドライブレコーダなどを利用した運転自動化技術レベル 1, 2 相当の ADAS へ応用可能な技術開発を目指した。本論文では路面上に拘束される車両下影を効果的に用いることによる単眼視での距離推定までを見据えた、リアルタイムで動作する先行車両検出及び追跡の実現を目的とし、「白線エッジ特徴を考慮したエッジ重畳による白線抽出」「車両下影に着目した車両識別による先行車両検出」「Particle Filter による影らしさと車両らしさを考慮した車両下影追跡」に関する研究を行った。以下に本論文の成果と今後の課題を述べる。

5.1 本論文の成果

(1) 白線エッジ特徴を考慮したエッジ重畳による道路白線抽出

従来の白線抽出は、エッジ抽出などにより白線の候補点を抽出し得られた候補点から直線を推定するものが多く、破線状の白線などで候補点が少ない場合に少ない候補点からでも抽出できるようにする取り組みが基本であった。

本論文では、破線状の白線候補点やかすれた白線候補点そのものを補完するエッジ重畳を基にした、シンプルで高速な白線抽出手法を提案した。具体的には、効果的なエッジ重畳を実現するための白線エッジ特徴を利用したエッジ抽出、リングバッファを用いたエッジ重畳、及び二段階で適用する連結画素走査を組み合わせた提案手法を構築した。実験より、平均処理時間 2ms で高速に動作し、実験シーンを平均して左右白線の推定誤差 3pixel 程度となり、高速道路及び一般道、昼夜や雨天等の環境において有効に働くことを明らかにした。

(2) 車両下影に着目した車両識別による先行車両検出

従来の影に着目した先行車両検出は、基本的に影の特徴表現として低輝度の水平エッジに着目するという手法が多く、この手法は車両下影抽出という点ではよいが車両下影の抽出をもって車両検出とするのは信頼性に欠けるほか、影のみをもって車両とすることで車両のスケールを考慮することが難しい点が課題としてあった。また、一般的な物体検出による車両検出では計算コストの高い処理で画像全体を走査する必要があった。

本論文では、輝度値が低いという影の特徴に基づき車両下影候補を抽出し、かつ車両下影候補の上部領域に対して機械学習により構築する車両識別器を適用して車両の有無を識別する2段階を踏むことで、車両としての信頼性を担保した高速な先行車両検出手法を提案した。実験より、平均処理時間20ms以内で動作し、高速道路昼及び一般道雨天夜の実験環境においても0.8以上のPrecisionとRecallを達成し、深層学習を用いた軽量の物体検出モデルと雨天夜の環境において比較するとPrecisionの0.03の低下に対しRecallが0.23向上するから、高速道路昼及び一般道雨天夜といった環境において提案手法が有効に働くことを明らかにした。

(3) Particle Filterによる影らしさと車両らしさを考慮した車両下影追跡

一般的な追跡手法では軽視される特徴である、物体領域内の端に位置する影の特徴を考慮した車両下影追跡手法を提案した。具体的には時系列フィルタリング手法のParticle Filter(PF)の枠組みを利用して、その尤度特徴に、輝度及びテクスチャによる影らしさと、物体追跡手法のKCFによる車両らしさを組み合わせた車両下影追跡手法を構築した。実験より、全ての実験環境において平均評価値0.82以上で最良となり、平均のy座標誤りも1pixel程度に抑えられたことから、影追跡が困難と考えられる夜間、雨天、逆光といった環境にも対応できることを明らかにした。

5.2 今後の課題

(1) 白線エッジ特徴を考慮したエッジ重畳による道路白線抽出

本論文で提案する道路白線抽出はリアルタイムで動作するため先行車両検出の前処理として機能し、車両下影を利用した車間距離推定において重要となる消失点の推定まで行える。この根幹を支えるエッジ重畳は、破線状の白線やペイントかすれに対応できる非常にシンプルながら強力な手法であるが、構造上自車両のハンドル操作等の影響が大きくなるため、それらの影響を抑制することが今後の研究課題である。また、実用上は道路白線の有無を検知できることが望ましいため、二段階連結画素走査をさらに発展させるほか、エッジ重畳画像を含む時系列データの処理により、現状の道路状況理解に繋がる枠組みにする必要がある。

(2) 車両下影に着目した車両識別による先行車両検出

本論文で提案する車両下影抽出は、高速かつ高精度な車両識別のために輝度値に加えテクスチャ特徴を利用して影候補領域と車両下影候補領域の区別を行うものである。本論文により、単眼車間距離推定のための車両特徴として車両下影を利用する基礎的な手法は構築できた。今後は車両識別処理をより高速かつ高精度に行えるようにすることが研究課題となる。Boosting を用いた識別器の高速適用手法としてはカスケード型識別器の構築が有効と考える。高精度化については層の浅い CNN 等を用いた特徴表現学習により、車両検出に有効な特徴量の抽出方法を自動的に学習し、それを Boosting により選択的に識別器に組み込む手法などが有効と考える。

(3) Particle Filter による影らしさと車両らしさを考慮した車両下影追跡

本論文で提案する車両下影追跡により、影領域と車両領域を同時に考慮することで、高精度に先行車両の下影を追跡する手法を構築できた。今後は先行車両が存在しなくなった場合への検討が研究課題となる。先行車両の有無は車両領域への影響がより大きいため、車両領域の追跡を担う KCF の出力の変化を基に、追跡対象の消失を検知する手法を検討する必要がある。また、車両検出と車両下影追跡を組み合わせたシステムとしての実装方法について検討する必要がある。

謝 辞

本論文は、日本大学理工学部応用情報工学科において、泉隆 特任教授、細野裕行 教授の指導の下に著者が行った研究をまとめたものである。近年注目され、進展が続く運転自動化の基盤技術を対象とした画像処理、画像認識に関する意義深い研究を進められたことは、ひとえに先生方の御指導の賜物である。心より御礼申し上げます。

香取照臣 教授には、本論文作成にあたり、有益な御助言と御討論をいただきましたこと、厚く御礼申し上げます。

伊藤彰義 日本大学名誉教授、本学電子工学科の塚本新 教授、中川活二 教授、本学精密機械工学科の齊藤健 准教授、本学応用情報工学科の高橋聖 教授、西脇大輔 教授、故 平山雅之 教授には、近年発展著しく本論文ともかかわりの深い分野である、深層学習に関する貴重な勉強の機会を与えていただきましたこと、感謝申し上げます。

本学交通システム工学科の福田敦 教授、石坂哲宏 准教授を中心に、小早川悟 教授、吉岡慶祐 助教、菊池浩紀 助手には、地球規模課題対応国際科学技術協力プログラム (SATREPS) の課題「マルチモーダル地域交通状況のセンシング、ネットワーキングとビッグデータ解析に基づくエネルギー低炭素社会実現を目指した新興国におけるスマートシティの構築」において交通センシングに関する興味深い研究に携わる機会を与えてくださり、御討論いただいておりますことを、感謝申し上げます。

また、本学応用情報工学科の田久保伸一 非常勤講師、滕琳 助教、高橋友彰 元助手及び、西安理工大学 魯曉鋒 副教授には著者が学生のころより度重なる御討論をいただきましたこと、感謝申し上げます。

最後に、日ごろ御指導、御鞭撻いただいております電気工学科、電子工学科及び応用情報工学科の諸先生方に深く感謝申し上げます。

著者発表論文

学術論文（査読付き） 4 件，国際会議 1 件，研究会・シンポジウム 14 件，
学会発表 34 件，その他発表 3 件，理工学部学術講演会 15 件

学術論文（査読付き）

- [1] 関 弘翔・泉 隆：「車両前方画像における影に着目した先行車両抽出」，電気学会論文誌D，Vol. 136, No. 1, pp.9-16 (2016)
- [2] 関 弘翔・泉 隆・細野裕行：「白線エッジ特徴を考慮したエッジ重畳による道路白線抽出」，電気学会論文誌A，Vol. 137, No. 1, pp.78-85 (2017)
- [3] 関 弘翔・泉 隆・細野裕行：「Particle Filterによる影らしさと車両らしさを考慮した先行車両追跡」，電気学会論文誌A，Vol. 139, No. 11, pp.585-595 (2019)
- [4] 柏山正守・柏山礼興・関 弘翔・細野裕行：「Pattern Match Acceleratorを用いたIoT Edge向けCyber-Securityの研究」，電気学会論文誌D，Vol. 140, No. 1, pp.15-28 (2020)

国際会議

- [1] T. Takahashi, L. Teng, T. Izumi, H. Seki: “An examination of Route Search considering the individual driver preferences,” 2015 IEEE Int. Conf. on Fuzzy Systems (2015)

研究会・シンポジウム

- [1] 関 弘翔・松原一樹・泉 隆：「車両前方画像における影に着目した先行車両抽出」，電気学会 ITS 研究会，ITS-13-18, pp. 13-16 (2013-06)
- [2] 魯 暁鋒・泉 隆・関 弘翔・高橋友彰：「パーティクルフィルタを用いた移動体検出に関する検討」，電気学会 ITS 交通・電気鉄道合同研究会，ITS-13-39 TER-13-65, pp. 53-56 (2013-11)
- [3] 魯 暁鋒・泉 隆・関 弘翔・高橋友彰：「パーティクルフィルタを用いた移動体の検出の精度向上に関する検討」，電気学会光応用・視覚／計測合同研究会，LAV-14-8 IM-14-8, pp. 7-10(2014-02)

- [4] 関 弘翔・泉 隆：「画像処理による影に着目した先行車両抽出 - 車両識別及び車両追跡 に関する検討 -」, 電気学会 ITS 研究会, ITS-14-25, pp. 23-26(2014-6)
- [5] 関 弘翔・泉 隆・田久保伸一：「画像処理による影に着目した先行車両抽出」, 第 12 回 ITS シンポジウム 2014 (2014-12)
- [6] 関 弘翔・泉 隆・高橋友彰・細野裕行：「画像処理によるエッジ重畳を用いた白線抽出に関する検討」, 電気学会計測／光応用・視覚合同研究会, IM-16-016, LAV-16-016 (2016-02)
- [7] 関 弘翔・泉 隆・細野裕行：「影に着目した先行車両追跡に関する検討」, 電気学会 ITS 研究会, ITS017-020, pp. 7-10 (2017-06)
- [8] 関 弘翔・泉 隆・細野裕行：「パーティクルフィルタを応用した影に基づく先行車両追跡」, 電気学会 ITS 交通・電気鉄道合同研究会, ITS-17-037, TER-17-063, pp. 1-6 (2017-11)
- [9] 高橋遥平・関 弘翔・泉 隆：「ステレオカメラを用いた重機向け近接者検知システム」, 電気学会計測／光応用・視覚合同研究会 (2018-02)
- [10] 関 弘翔・泉 隆・細野裕行：「相関フィルタを応用した先行車両追跡に関する検討」, 電気学会 ITS 研究会, ITS-18-012, pp. 5-10 (2018-06)
- [11] 関 弘翔・泉 隆・細野裕行：「影に着目した先行車両追跡に関する検討」, 電気学会計測／光応用・視覚合同研究会, LAV-19-013, IM-19-013 (2019-03)
- [12] 柏山正守・関 弘翔・細野裕行：「Pattern Match Accelerator を用いた Edge 向け Malware Cyber-Security の検討」, 電気学会 ITS 研究会, ITS-19-019, pp. 37-42 (2019-09)
- [13] 小池湧大・関 弘翔・松野 裕：「開発・運用アシュアランスケースによる機械学習システムのディペンダビリティ保証」, 第 17 回 ディペンダブルシステムワークショップ (DSW 2019) (2019-12)
- [14] 柏山正守・関 弘翔・細野裕行：「CASE クルマの Cyber Security 実装検討」, 第 17 回 ITS シンポジウム 2019, 1-A-09 (2019-12)

学会発表

- [1] 関 弘翔・松原一樹・泉 隆：「車両前方画像における影に着目した先行車両抽出～Haar-like特徴量による車両抽出の検討～」，平成24年（第8回）電気学会東京支部千葉支所研究発表会，1-7，p. 9 (2012-11)
- [2] 関 弘翔・松原一樹・泉 隆：「車両前方画像における影に着目した先行車両抽出～Haar-like 特徴量による車両識別の検討～」，第3回3学会共催大会～第39回ファジィ・ワークショップ～，pp. 73-74 (2013-03)
- [3] 関 弘翔・松原一樹・泉 隆：「車両前方画像における影に着目した先行車両抽出 - Haar-like 特徴量による車両識別の検討 - 」，平成25年電気学会産業応用部門大会，YPC，Y-137 (2013-08)
- [4] 石橋 諒・魯 暁鋒・関 弘翔・泉 隆：「車両前方画像を用いた先行車両抽出～マルチバッファを用いたエッジ重畳の最適化～」，平成25年（第9回）電気学会東京支部千葉支所研究発表会，3-6，p. 26 (2013-11)
- [5] 石橋 諒・魯 暁鋒・関 弘翔・泉 隆：「車両前方画像を用いた先行車両抽出～マルチバッファを用いたエッジ重畳の最適化～」，平成26年電気学会全国大会，Vol. 4，No. 207，p. 324 (2014-03)
- [6] 関 弘翔・泉 隆：「画像処理による影に着目した先行車両抽出 - 車両識別及び車両追跡 に関する検討 - 」，平成26年電気学会全国大会，Vol. 4，No. 208，p. 325 (2014-03)
- [7] 魯 暁鋒・泉 隆・関 弘翔・高橋友彰：「パーティクルフィルタを用いた単一移動体追跡」，平成26年電気学会全国大会，Vol. 4，No. 209，pp. 326-327 (2014-03)
- [8] 関 弘翔・泉 隆・田久保伸一：「車両前方画像における影に着目した先行車両抽出 - 車両識別及び車両追跡に関する検討 - 」，平成26年電気学会産業応用部門大会，YPC，Y-121(2014-08)
- [9] 矢口 弘・石橋 諒・関 弘翔・泉 隆：「車両前方画像における白線抽出～リングバッファを用いたエッジ重畳フレーム数の検討～」，平成26年（第10回）電気学会東京支部千葉支所研究発表会，1-2，p. 4(2014-11)

- [10] 平山 拓・関 弘翔・高橋友彰・泉 隆：「ロボカーを利用した安全運転支援に関する検討」，平成 26 年（第 10 回）電気学会東京支部千葉支所研究発表会，1-3，p.5(2014-11)
- [11] 関 弘翔・泉 隆：「車両前方画像における白線抽出手法の改善」，2015 年電子情報通信学会総合大会，A-17-14 (2015-03)
- [12] 石橋 諒・関 弘翔・泉 隆：「車両前方画像における先行車両抽出—明度に着目した黄色線抽出—」，平成 27 年電気学会全国大会，4-224 (2015-03)
- [13] 林 尚史・白井志朗・関 弘翔・細野裕行：「LED 照明システムにおける PN 符号を用いた電力線搬送通信の検討」，2015 年電子情報通信学会ソサイエティ大会，B-8-22 (2015-08)
- [14] 関 弘翔・泉 隆・細野裕行：「画像処理によるエッジ重畳を用いた道路白線抽出の改善」，平成27年電気学会産業応用部門大会，YPC，Y-141(2015-09)
- [15] 関 弘翔・泉 隆：「画像処理による先行車両抽出」，平成27年電気学会産業応用部門大会，4-S4-1 (2015-09)
- [16] 山田 巧・関 弘翔・高橋友彰・泉 隆：「リングバッファを用いたエッジ重畳による白線抽出精度に関する検討」，平成27年（第11回）電気学会東京支部千葉支所研究発表会，1-3，p.5(2015-10)
- [17] 林 尚史・白井志朗・関 弘翔・細野裕行：「LED 照明システムにおける PN 符号を用いた電力線搬送通信-電力変動抑制方式の検討-」，2016 年電子情報通信学会総合大会，B-8-53 (2016-03)
- [18] 関 弘翔・泉 隆・細野裕行：「画像処理によるエッジ重畳を用いた白線抽出 - バッファ閾値処理によるノイズ抑制の検討 - 」，平成28年電気学会全国大会，4-210 (2016-03)
- [19] 松本達矢・山田 巧・関 弘翔・泉 隆：「画像処理を用いた先行車両抽出のための白線検出」，日本知能情報ファジィ学会 第42回ファジィ・ワークショップ (2016-3)
- [20] 関 弘翔・泉 隆・細野裕行：「画像処理によるエッジ重畳を用いた白線抽出—分割重畳による抽出精度向上の検討—」，平成28年電気学会基礎・材料・共通部門大会，5-C-a2-4 (2016-09)

- [21] 五味悠一郎・関 弘翔・平山雅之：「専門科目と連携した課題実験による組込みシステム教育の実践」，FIT2016 第15回情報科学技術フォーラム，K-012 (2016-9)
- [22] 高橋遥平・関 弘翔・泉 隆：「最小二乗法による道路白線の直線近似」，2016年（平成28年）第12回電気学会東京支部千葉支所研究発表会，1-4 (2016-10)
- [23] 関 弘翔・泉 隆・細野裕行：「パーティクルフィルタを応用した先行車両追跡に関する検討」，平成29年電気学会全国大会，4-232 (2017-03)
- [24] 高橋遥平・関 弘翔・泉 隆：「最小二乗法を用いた直線近似による白線抽出の検討」，平成29年電気学会全国大会，4-233 (2017-03)
- [25] 高橋遥平・関 弘翔・泉 隆：「最小二乗法を用いた白線抽出に関する検討」，平成29年電気学会産業応用部門大会，Y-146 (2017-08)
- [26] 高橋遥平・関 弘翔・泉 隆：「ステレオカメラを用いた近接者検知システムの検討」，平成29年電気学会電子・情報・システム部門大会，PS6-11 (2017-08)
- [27] 関 弘翔・泉 隆・細野裕行：「影に着目した先行車両追跡」，平成30年電気学会産業応用部門大会，4-S4-3 (2018-09)
- [28] 後藤悠希・高橋遥平・関 弘翔・泉 隆：「パーティクルフィルタを用いた先行車両追跡」，2018年（平成30年）第14回電気学会東京支部千葉支所研究発表会 (2018)
- [29] 古川貴大・関 弘翔・細野裕行：「SegNet Basic に基づく顔領域分割の精度向上に関する検討」，平成31年電気学会全国大会，3-112 (2019-03)
- [30] 後藤悠希・高橋遥平・関 弘翔・泉 隆：「複数尤度によるパーティクルフィルタを用いた先行車両追跡」，平成31年電気学会全国大会，4-276 (2019-03)
- [31] 関 弘翔・泉 隆・古川貴大・細野裕行：「道路画像の意味的領域分割に関する一考察」，平成31年電気学会産業応用部門大会，4-S6-3 (2019-08)
- [32] 柏山正守・関 弘翔・細野裕行：「Pattern Macth Accelerator を用いた Mobility IoT 向け Malware 検出の検討」，平成31年電気学会産業応用部門大会，4-S6-4 (2019-08)
- [33] 古川貴大・関 弘翔・細野裕行：「Mask R-CNN を基とした顔検出及び顔領域分割に関する検討」，2020年電子情報通信学会総合大会，D-12-47 (2020-03)
- [34] 藤岡紘展・関 弘翔・細野裕行：「骨導音声の認識率向上の検討」，2020年電子情報通信学会総合大会，D-14-5 (2020-03)

その他発表

- [1] H. Seki, T. Izumi, and T. Takahashi: “Vehicle Detection Based on Shadow using Image Processing”, The 3rd International Symposium on Information Technology and Application (ISITA2014), pp. 51-58 (2014-10)
- [2] H. Seki, T. Izumi, and H. Hosono: “White Line Detection with Image Processing,” The 4th International Symposium on Information Technology and Application (ISITA2015), pp.19-28 (2015-11)
- [3] 高橋遥平・関 弘翔・泉 隆:「深度カメラを用いた重機向け近接者検知システムの構築」, 日本大学ロボティクスソサエティ (NUROS) 設立シンポジウム (2019-03)

理工学部学術講演会

- [1] 関 弘翔・堀江忠裕・松原一樹・泉 隆:「車両前方画像における影に着目した先行車両抽出 - Haar-Like特徴量による車両抽出の検討 - 」, 平成24年度 (第56回) 日本大学理工学部学術講演会, G-19, pp. 537-538 (2012-11)
- [2] 関 弘翔・泉 隆:「車両前方画像における影に着目した先行車両抽出 - 車両識別及び車両追跡に関する検討 - 」, 平成 25 年度 (第 57 回) 日本大学理工学部学術講演会, G-3, p. 443-444 (2013-12)
- [3] 関 弘翔・泉 隆:「車両前方画像における影に着目した先行車両抽出 - 白線抽出のためのエッジ抽出手法に関する検討 - 」, 平成 26 年度 (第 58 回) 日本大学理工学部学術講演会, G-4, pp. 415-416 (2014-12)
- [4] 林 尚史・白井志朗・関 弘翔・細野裕行:「LED 照明システムにおける PN 符号を用いた電力線搬送通信-雑音に対する検討-」, 平成 27 年度 (第 59 回) 日本大学理工学部学術講演会, G-7, pp. 413-414 (2015-12)
- [5] 高橋遥平・関 弘翔・泉 隆:「最小二乗法による道路白線の直線近似」, 平成 28 年度 (第 60 回) 日本大学理工学部学術講演会, G-3, pp.448-449 (2016-12)
- [6] 藤岡紘展・関 弘翔・細野裕行:「骨導音の周波数解析」, 平成29年度 (第61回) 日本大学理工学部学術講演会, G-11, pp.479-480 (2017-12)

- [7] 古川貴大・関 弘翔・細野裕行：「歯科診療ライトの自動照準システムのための画像処理を用いた顔検出に関する検討」，平成29年度（第61回）日本大学工学部学術講演会，G-23, pp.503-504 (2017-12)
- [8] 高橋遥平・関 弘翔・泉 隆：「ステレオカメラを用いた重機向け近接者検知システムの構築」，平成 29 年度（第 61 回）日本大学工学部学術講演会，G-26, pp.509-510 (2017-12)
- [9] 古川貴大・関 弘翔・細野裕行：「Semantic Segmentation を用いた顔領域分割 - SegNet Basic に基づく顔領域分割の精度向上に関する検討 - 」，平成 30 年度（第 62 回）日本大学工学部学術講演会，G-5, pp.519-520 (2018-12)
- [10] 藤岡紘展・関 弘翔・細野裕行：「骨導マイクロホン及び咽喉マイクロホンを 用いた音声認識に関する研究 - 骨導マイクロホン及び咽喉マイクロホンの周波数特性 - 」，平成 30 年度（第 62 回）日本大学工学部学術講演会，G-6, pp.521-522 (2018-12)
- [11] 高橋遥平・関 弘翔・泉 隆：「深度カメラを用いた近接者検知システムの構築に関する研究」，平成 30 年度（第 62 回）日本大学工学部学術講演会，G-21, pp.551-552 (2018-12)
- [12] 藤岡紘展・関 弘翔・細野裕行：「骨導音声の認識率向上の検討 - 深層学習を用いたスペクトログラム補正 - 」，令和元年度（第 63 回）日本大学工学部学術講演会，G-1, pp.412-413 (2019-12)
- [13] 古川貴大・関 弘翔・細野裕行：「End-to-end モデルによる顔検出及び顔領域分割に関する検討」，令和元年度（第 63 回）日本大学工学部学術講演会，G-3, pp.416-417 (2019-12)
- [14] 佐々木駿・藤岡紘展・関 弘翔・細野裕行：「ニューラルネットワークを用いた生活音識別」，令和元年度（第 63 回）日本大学工学部学術講演会，G-18, pp.440-441 (2019-12)
- [15] 斎藤大嗣・関 弘翔・細野裕行：「深層学習による物体検出を用いた交通量計測」，令和元年度（第 63 回）日本大学工学部学術講演会，G-19, pp.442-443 (2019-12)