

路側設置ステレオマイクを用いた車両種別推定手法の 初期的評価

石田 繁巳^{1,a)} 内野 雅人¹ 小池 大地¹ 田頭 茂明² 福田 晃¹

概要: 高度道路交通システム (ITS: Intelligent Transportation System) において, 道路上を通行する車両を車両種別を識別しながら検出することは重要な機能の1つである. 筆者らはステレオマイクを用いた車両検出システムの開発を進めている. 本稿ではこの車両検出システムを拡張し, 検出した車両の走行音を解析し, 車両種別を推定する手法を示す. 実環境では複数車線の道路での利用が想定されることから, マイクの前をほぼ同時に通過する車両の音が混ざり車両種別推定精度が低下することが予想される. このため, ステレオマイクを用いて車両の移動を追尾しながら車両走行音を解析して高い精度での車両種別推定を実現する. 九州大学伊都キャンパス内の道路で収集した走行音データを用いて初期的評価を行い, 平均精度 95.01% で車両種別を推定できることを確認した.

Initial Evaluation of Vehicle Type Estimation using Sidewalk Stereo Microphones

Shigemi Ishida^{1,a)} Masato Uchino¹ Daichi Koike¹ Shigeaki Tagashira² Akira Fukuda¹

1. はじめに

近年の情報通信技術の発展とともに, 高度道路交通システム (ITS: Intelligent Transportation System) の研究開発が進んでいる. 交通状況を加味した道案内を行うカーナビゲーションシステム, オートクルーズシステム, 自動運転などは ITS アプリケーションの最たる例である. 道路交通の安全性, 効率, 利便性, 信頼性の向上に向け, さまざまな ITS アプリケーションが提案, 実現されつつある.

さまざまな ITS アプリケーションにおいて道路上を通過する車両の検出及び検出した車両の種別を識別することは重要な機能である. 車両検出に向けてはこれまでにいくつかの車両検出手法が提案されており, 道路には赤外線を用いた車両検出センサなどの導入がすでに進んでいる. 筆者らもステレオマイクを用いた低コスト車両検出手法を提案した [1, 2].

しかしながら, これらの車両検出技術は車両の検出を主眼としており, 車両種別の識別に関しては考慮されていない. これまでの車両検出技術は低コストかつ高精度に車両を検出することを目指して研究開発が進められてきた. ITS 技術の進歩とともに車両の検出だけでなくどのような車両が通過したかを識別したいという要求が高まる中, 車両種別識別の研究は進んでいない. CCTV のようなカメラを利用する車両検出技術 [3, 4] は画像認識技術と組み合わせることで車両の検出と車両種別推定を同時に実現可能と考えられるが, 導入コストや設置の制約などの問題から導入は進んでいない.

このような問題に対し, 本稿ではステレオマイクを用いて車両検出と車両種別推定の両方を同時に実現する手法を示す. 筆者らの提案したステレオマイクを用いる車両検出手法によって車両を検出し, 検出した車両の走行音の周波数成分を解析して機械学習によって車両種別を推定する.

現実環境では複数の車線が存在するため, マイクの前をほぼ同時に通過した車両の音が混ざることによって種別推定精度の低下が予想される. このため, ステレオマイクを用いて車両の移動を追尾しながら走行音を解析し, 高い精度での種別推定を実現する. 九州大学伊都キャンパス内の道路で

¹ 九州大学大学院システム情報科学研究所
ISEE, Kyushu University, Fukuoka 819-0395, Japan

² 関西大学総合情報学部
Faculty of Informatics, Kansai University, Osaka, 569-1095, Japan

a) ishida@f.ait.kyushu-u.ac.jp

収集した走行音データを用いて初期的評価を行った結果、平均精度 95.01% で車両種別を推定できることを確認した。

本稿の構成は以下の通りである。2. では車両種別推定の関連研究を述べる。3. では車両種別推定手法を示し、その初期的評価を 4. で示す。最後に 5. でまとめとする。

2. 関連研究

2.1 音響センサを用いない車両種別推定手法

音響センサを用いずに車両種別を推定する手法として ETC (電子料金授受システム: Electronic Toll Collection System) を用いる手法やカメラを用いた手法が挙げられる。

ETC を用いる手法では、ETC 車載器から得た車両登録情報によって車両種別を識別する。日本では高速道路において ETC が広く利用されており、高速道路においては車両の通過と通過車両の種別識別を同時に実現可能である。一方で、設置・メンテナンスのコストを考慮すると車両の通過検知・種別識別のためだけに一般道に ETC を設置することは考えづらく、有料道路以外への導入は進んでいない。

カメラを用いる手法としては、車両のナンバープレートや車両長に基づく種別推定手法が報告されている。Hongliang らはナンバープレートを用いて車両種別を推定するシステムの開発を行っている [5]。カメラで取得した画像に対して垂直方向のエッジ検出を行った上で統計的に分析することで、ナンバープレートの位置及びナンバープレートの特徴量抽出を行っている。この手法は高い精度での種別推定が確認されているが、解析のために高性能な計算機が必要となること、高精度を実現するために車両の前方上空にカメラを設置する工事が必要となることなどの理由から導入は進んでいない。

Avery らは車両長を用いた種別推定手法を示している [6]。主要道路に設置された監視カメラで取得した画像に対し背景差分をとることで車両を検出し、道路の一定区間内を車両が通過する際に要した時間を相対比較することで車両長に基づく種別推定を行っている。この手法はトラックといった車両長の大きいものの分類には適しているが、バイクや小型車などの車両長の短い車両に対しては推定精度が低いという問題がある。また、雨天や濃霧など天候の影響により精度が低下するという問題がある。

2.2 音響センサを用いた車両種別推定手法

低コストな車両種別推定手法として、マイクを用いる手法が報告されている。Aljaafreh ら、Changjun らは周波数領域の特徴量を用い、SVM (Support Vector Machine) 及び k-NN (k 近傍法: k-Nearest Neighbor) による教師あり学習ベースの車両種別推定手法を示している [7, 8]。Munich らは周波数領域の特徴量を用い、GMM (ガウス混合モデル: Gaussian Mixture Model) 及び HMM (隠れマルコフモデル: Hidden Markov Model) による教師あり学習ベースの車両種別推定手法を示し、これらの推定精度比較を

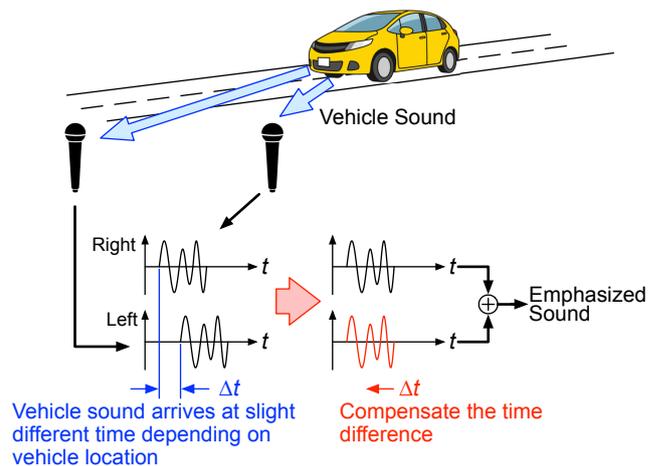


図 1 ステレオマイクを用いた車両種別推定の基本アイデア

行っている [9]。これらの手法は、マイクを用いて車両種別を推定する際に最適な機械学習アルゴリズムや特徴量を決定する上で有用である。

Yang らは車両音の周波数スペクトラム形状を用いて車両を推定する手法を示している [10]。車両音の周波数成分に着目するのではなく、周波数スペクトラム全体の形状を特徴量とすることで同一車両の推定を実現している。周波数スペクトラム全体の分布は車両固有のものであるため、単一の車両の推定において高精度の種別が確認されている。しかしながら、同じ車両種別であっても車両の個体ごとに周波数スペクトラムは異なるため、車両の種別を推定することは困難である。

いずれの研究も複数の車両音が混ざった状況での推定については考慮されていない。現実環境では複数の車線をほぼ同時に車両が通過する「同時通過」や、同一車線を連続して車両が通過する「連続通過」という状況が想定される。また、バイクが車両の横を走行している場合にも同時通過が発生しうる。このような場合、複数の車両の走行音が混ざるため車両種別推定精度が低下する。

3. 設計

3.1 基本アイデア

ステレオマイクを用いた車両種別推定手法の基本アイデアは、車両の移動を追尾し、車両方向の音を強調しながら解析して車両種別を推定することである。2 台のマイクを道路横に道路と平行に設置すると、車両がマイクの目の前にない場合には車両と各マイクの間距離が異なるため、車両走行音がマイクに到達するまでには時間差が生じる。そこで、2 台のマイクが受信した車両走行音の時間差を補正した上で重ね合わせることで車両走行音を強調する。

図 1 は道路に向かって右方向に車両が存在する場合の例を示している。この場合、左チャンネルのマイクは右チャンネルのマイクよりも車両から遠い位置に存在するため、左チャンネルのマイクが車両走行音を受信する時刻は右チャンネルよりも遅くなる。この受信時刻の差を Δt とする。ス

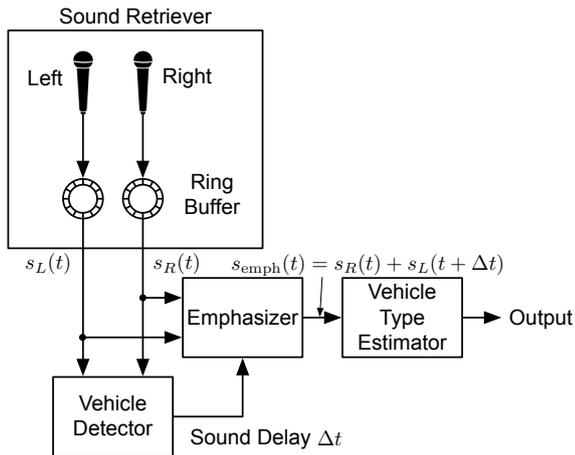


図2 ステレオマイクを用いた車両種別推定システムの概要

ステレオマイクを用いた車両種別推定手法では、左チャンネルの音声を $-\Delta t$ だけずらした上で右チャンネルの音声を足し合わせることで強調音声を得る。すなわち、 $s_L(t)$, $s_R(t)$, をそれぞれ左右チャンネルの音声信号とすると、強調音声 $s_{\text{emph}}(t)$ は

$$s_{\text{emph}}(t) = s_R(t) + s_L(t + \Delta t) \quad (1)$$

である。この強調音声を用いて教師あり学習により車両種別を推定する。

車両は道路を走行しているため、受信時刻差 Δt は時刻とともに変化する。このため、実際には Δt も時刻 t の関数であるとして強調処理を行う。

$$s_{\text{emph}}(t) = s_R(t) + s_L[t + \Delta t(t)] \quad (2)$$

3.2 システム概要

図2にステレオマイクを用いた車両種別推定システムの概要を示す。ステレオマイクを用いた車両種別推定システムは、走行音取得ブロック (Sound Retriever), 車両検出ブロック (Vehicle Detector), 強調合成ブロック (Emphasizer), 車両種別推定ブロック (Vehicle Type Estimator) の4つのブロックで構成される。走行音取得ブロックで取得した音声信号を車両検出ブロックで解析して車両を検出し、車両の通過時刻及び音声信号の受信時間差 Δt を取得する。車両検出ブロックは先行研究のSAVeDを用いて実現する [2, 11]。取得した Δt を用いて強調合成ブロックにおいて左右マイクで取得した音声信号を重ね合わせ、車両方向の音を強調する。強調された音声信号から周波数領域で特徴量を抽出し、車両種別推定ブロックにおいて教師あり学習により車両種別を推定する。

以下では各ブロックについて詳述する。

3.3 走行音取得ブロック

走行音取得ブロックではステレオマイクを用いて走行音を取得する。図3にマイクの設置状態を示す。2台のマイ

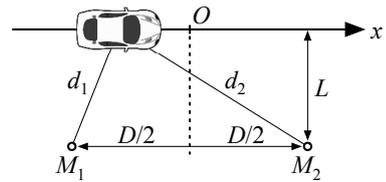


図3 マイクロフォンの設置

ク M_1 , M_2 をマイク間の距離 D , 道路からの距離 L だけ離して設置し、音声を取得する。車両の位置に応じて車両から各マイクまでの距離 d_1 , d_2 の差が変化することから、走行音が両マイクに到達するまでには時間差が生じる。この時間差を利用して車両の検出、車両種別の推定を行うため、両マイクで取得した音声をリングバッファを用いて一定時間分保存しておく。

3.4 車両検出ブロック

車両検出ブロックはリングバッファに格納されている音声信号を用いて「サウンドマップ」を描くことで車両を検出する。サウンドマップは2台のマイクにおける走行音の受信時間差の時間変化を示した図である。相互相関関数を用いて推定した走行音受信時間差を時間の関数として描くことで得られる。2台のマイクが受信した音声信号を $s_1(t)$, $s_2(t)$ とすると、相互相関関数 $R(t)$ は

$$R(t) = \int s_1(t) s_2(t + \tau) d\tau \quad (3)$$

と定義される。2台のマイクが時間差 Δt の信号を受信、すなわち $s_1(t) = s_2(t + \Delta t)$ であるとする $R(t)$ は $t = \Delta t$ において最大値を取る。このため、 $R(t)$ のピークを探すことで走行音の受信時間差 Δt を推定できる。実際の受信時間差の計算では周波数領域で時間差を計算するGCC-PHAT (Generalized Cross-Correlation Phase Transform) を用いる。

車両が一定速度 v でマイクの前を通過する場合、サウンドマップ上にはS字のカーブが描かれる。車両がマイクの目の前を通過する時刻を $t = t_0$ とすると、図3においてマイク M_1 , M_2 における車両走行音の受信時間差 (Sound Delay) Δt は走行音が各マイクに到達するまでの距離 d_1 , d_2 の差から以下のように求められる。

$$\begin{aligned} \Delta t &= \frac{d_1 - d_2}{c} \\ &= \frac{1}{c} \left\{ \sqrt{\left[v(t - t_0) + \frac{D}{2} \right]^2 + L^2} \right. \\ &\quad \left. - \sqrt{\left[v(t - t_0) - \frac{D}{2} \right]^2 + L^2} \right\} \quad (4) \end{aligned}$$

ここで、 c は音速である。式 (4) より、 t が線形に増加または減少するとサウンドマップ上にはS字のカーブが描かれることが分かる。

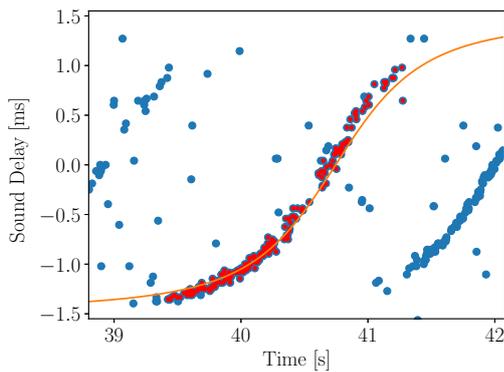


図 4 サウンドマップ及び RANSAC による車両検出の例

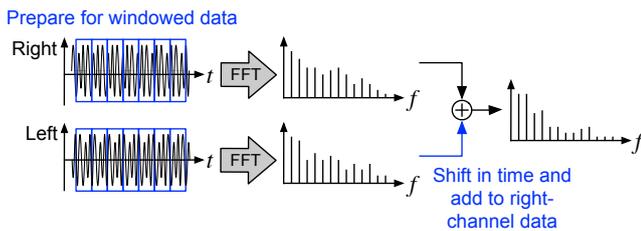


図 5 強調合成処理の概要

車両検出ブロックではロバスト推定手法 RANSAC (random sample consensus) [12] を用いてサウンドマップ上の S 字カーブを検出することで車両を検出する。式 (4) において未知のパラメータは速度 v 及びマイク前通過時刻 t_0 であるから、サウンドマップ上の点群のうち尤もらしいものに式 (4) をフィッティングすることで v 及び t_0 を推定する。

図 4 にサウンドマップ及び RANSAC による車両検出の例を示す。図中の青い点は各時刻における走行音の受信時間差、線は RANSAC によって式 (4) をフィッティングした結果を示している。赤い点は「尤もらしい」と判断されてフィッティング時に利用された点群である。S 字カーブから大きく外れた点が含まれていても RANSAC を用いて尤もらしい v , t_0 を推定することが可能である。検出した各車両に対して、車両検出ブロックは速度 v 及び通過時刻 t_0 を強調合成ブロックに対して出力する。

3.5 強調合成ブロック

強調合成ブロックでは、車両検出ブロックが検出した各車両について、速度 v 及び通過時刻 t_0 を用いて各時刻における走行音時間差を計算し、時間をシフトして左右チャンネルの音を足し合わせる。図 5 に、強調合成処理の概要を示す。音声信号データをウィンドウに区切って逐次的に処理するため、時間シフトは周波数領域で行う。まず、左右各チャンネルの音声信号を固定幅のウィンドウで区切り、各ウィンドウの音声信号データに高速フーリエ変換 (FFT: Fast Fourier Transform) を適用して周波数領域表現データを得る。次に、車両検出ブロックから取得した速度 v 及び通過時刻 t_0 を式 (4) に代入してウィンドウ内の各時刻に

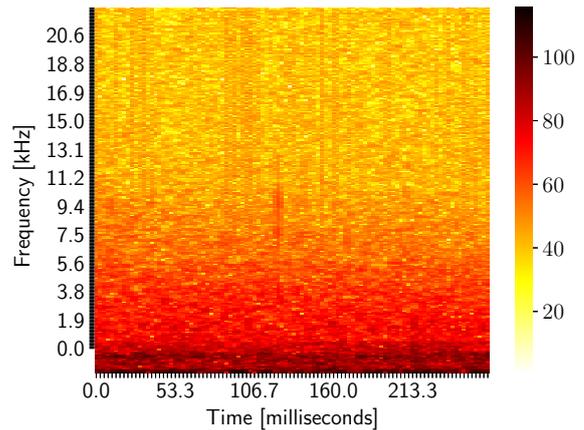


図 6 車両が通過している際に取得した音声信号の周波数スペクトラム [dB]

おける車両走行音の時間差を計算する。最後に、計算された時間差を打ち消すように音声信号を時間シフトして足し合わせる。なお、音声信号の周波数領域表現データは車両検出ブロックにおける GCC-PHAT にて計算したものを利用できる。

周波数領域における時間方向のシフトは、各周波数成分の位相シフトである。音声信号データのサンプル、すなわち時間領域表現を $s[n]$ とすると、その周波数領域表現 $S[k]$ は離散フーリエ変換を用いて以下のように表せる。

$$S[k] = \text{DFT}(s[n]) = \sum_{n=0}^{N-1} s[n] e^{-j2\pi k \frac{n}{N}} \quad (5)$$

ここで、 $\text{DFT}(\cdot)$ は離散フーリエ変換、 N は離散フーリエ変換の点数 (= ウィンドウサイズ) である。時間領域信号 $s[n]$ を m 点だけ右に移動させた信号、すなわち m 点だけ時間を遅延させた信号 $s[n-m]$ の離散フーリエ変換は以下のように変形できる。

$$\text{DFT}(s[n-m]) = \sum_{n=0}^{N-1} s[n-m] e^{-j2\pi k \frac{n}{N}} = e^{-j2\pi k \frac{m}{N}} S[k] \quad (6)$$

式 (6) より、各周波数成分の位相を $-2\pi k \frac{m}{N}$ だけシフトさせることで時間シフトさせることができることが分かる。

3.5.1 車両種別推定ブロック

車両種別推定ブロックでは、強調合成ブロックで強調された走行音の周波数領域表現から車両種別推定に用いる特徴量を抽出し、教師あり学習により車両種別を推定する。本稿では使用する機械学習手法は特に限定しない。複数の車両種別を推定するため、多クラス分類を行う教師あり学習手法であればどのようなものでも適用可能である。本稿では、多クラス分類を行う教師あり学習手法の代表例として SVM を用いて車両種別の推定を行う。

車両種別推定では強調合成ブロックから出力された音声

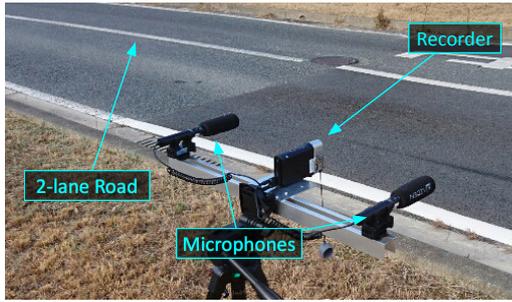


図 7 評価環境

信号の周波数スペクトラムのうち低周波成分のみを特徴量として利用する。図 6 は、車両が通過している際に取得した音声信号の周波数スペクトラムの時間変化の例を示している。図より、車両通過時の音声信号には 10 kHz 以下の周波数成分が多く含まれていることが分かる。このため、10 kHz 以下の周波数成分のみを取りだして車両種別推定に利用する。

環境ノイズなどの影響を軽減するため、機械学習による分類器に入力する前に各周波数成分の時間変化に対して LPF (低域通過フィルタ: Low Pass Filter) を適用する。図 6 の横軸は時刻であり、数百ミリ秒という短い時間では音声信号の周波数スペクトラムは大きく変化していないことが分かる。一方で、環境ノイズなどの影響によって周波数スペクトラムは短い時間にも小幅に変化している。車両がマイクの前を通過するのに要する時間は数秒程度と比較的長いことから、車両通過時間に比べて短い時間で移動平均を行うことでこの小さな変化の影響を軽減する。予備実験の結果に基づき、移動平均の長さは 320 ミリ秒とした。

学習効率や学習精度の向上に向け、全ての特徴量には標準化処理を施す。各周波数 f の特徴量について学習データの平均 μ_f 及び標準偏差 σ_f を計算し、推定に用いる各データ $x_f[i]$ に対して $(x_f[i] - \mu_f) / \sigma_f$ を計算した上で分類器に入力する。

4. 評価

ステレオマイクを用いた車両種別推定手法の有効性を検証するため、九州大学伊都キャンパス内の道路において収集した車両走行音データを用いて初期的評価を行った。

4.1 評価環境

図 7 に評価環境を示す。走行音を収集した道路は片側 1 車線、合計 2 車線の道路であり、両車線を走行する車両を種別推定の対象とした。2 台のマイクを道路横に道路と平行に高さ約 1 m で設置し、ビデオカメラに接続して車両の走行音を約 20 分間記録した。ビデオカメラは SONY 社製 HDR-MV1、マイクは AZDEN 社製 SGM-990 である。走行音はサンプリングレート 48 kHz、量子化ビット数 16 bit で記録した。文献 [2] と同様にマイクの間隔 D は 50 cm、道路の中心・マイク間の距離は手前の車線で $L = 3$ m、奥

の車線で $L = 6$ m である。

取得した音声信号に対して 3. で示した手法を適用し、SVM による多クラス分類問題として車両種別を推定した。車両種別の真値はビデオカメラで撮影した映像に基づいて手動でラベル付けした。実験中に通過した車両種別ごとの台数は普通車 57 台、バイク 94 台、バス 25 台、トラック 2 台であった。トラックは通過台数が少なかったため評価から除外し、普通車、バイク、バスの 3 種類の推定を行った。車両種別の推定には車両検出ブロックにおける車両検出が前提となるため、車両検出ブロックが検出した普通車 46 台、バイク 78 台、バス 18 台を評価に用いた。

車両がマイクの前を通過するのに要する時間を車両通過時間 T_{pass} と定め、車両種別推定には車両 i の通過時刻を $t = t_{0,i}$ として $t_{0,i} - T_{\text{pass}}/2 \sim t_{0,i} + T_{\text{pass}}/2$ の範囲の音声信号を用いた。各車両種別ごとに通過台数が異なることから、各車両種別のデータが同量となるように無作為にアンダーサンプリングした。Leave-one-out 10 分割交差検証により各 FFT ウィンドウで車両種別を推定し、混同行列を得た。

評価では、以下の 2 つの手法の推定精度を比較した。

(1) ステレオ推定手法:

3. で示した提案手法である。車両検出時の情報を用いて 2 台のマイクの音声合成して走行音を強調し、教師あり学習により車両種別を推定した。

(2) モノラル推定手法:

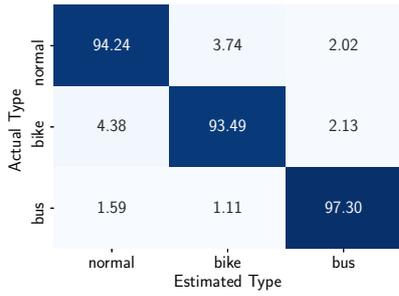
1 台のマイクを用いて車両種別を推定する手法である。本稿の評価環境では 2 台のマイクを用いているため、左側のマイクの音声信号のみを使って教師あり学習により車両種別を推定した。

4.2 車両種別推定精度

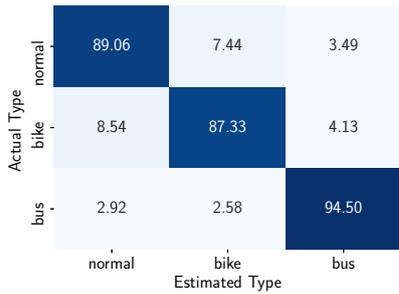
10 分割交差検証の試行回数を 100 回として車両種別推定を行い、混同行列を得た上で推定精度を評価した。推定精度は全試行に対する正しい推定の割合である。FFT のウィンドウ長は 4096 点であり、25% オーバーラップさせながら FFT ウィンドウをシフトして各ウィンドウで車両種別を推定した。車両通過時間 T_{pass} は予備実験の結果に基づいて $T_{\text{pass}} = 2.0$ s とした。

図 8 に車両種別推定結果の混同行列を示す。図の (a) はステレオ推定手法、(b) はモノラル推定手法の混同行列をそれぞれ示している。ステレオ、モノラル推定手法の推定精度はそれぞれ 95.01%、90.30% であり、ステレオ推定手法によって推定精度は 4.71% 向上した。車両種別ごとに見ても全車両種別で推定精度が向上している。車両方向の音を強調することで推定精度を向上できたと考えられる。

ステレオ推定手法による推定精度の向上幅は車両種別ごとに異なる。車両種別ごとの推定精度向上幅は、普通車 5.18%、バイク 6.16%、バス 2.79% である。推定精度向上幅の違いは、ステレオ推定手法による推定精度向上が主



(a)



(b)

図 8 車両種別推定結果の混同行列: (a) ステレオ推定手法, (b) モノラル推定手法. 推定精度はそれぞれ 95.01%, 90.30%.

表 1 車両種別ごとの検出台数と, 検出台数に占める同時 (Simultaneous), 連続 (Successive) 通過台数及びその割合

	Normal	Bike	Bus	Total
Detected	46	78	18	142
Simultaneous	11 (23.91%)	33 (42.31%)	2 (23.91%)	46 (32.39%)
Successive	6 (13.04%)	10 (12.82%)	3 (16.67%)	19 (13.38%)
Total	17 (36.96%)	43 (55.13%)	5 (27.78%)	65 (45.77%)

に同時・連続通過車両に対するものであるためと考えられる。表 1 は車両種別ごとの検出台数と, そのうちの同時 (Simultaneous), 連続 (Successive) 通過台数及びその割合を示している。同時, 連続通過台数の割合は車両種別ごとに計算したものである。同時, 連続通過車両の定義は「通過時刻の前後合計 T_{pass} 以内に別の車両が通過した車両」である。その「別の車両」と対象の車両の進行方向が同方向の場合を同時通過, 逆方向の場合を連続通過と定義した。表 1 より, 通過台数に占める同時・連続通過車両の割合の高い順に精度向上幅が大きくなっていることが分かる。一方で, 同時・連続通過車両の割合と精度向上幅は比例関係にないことから必ずしも全ての同時・連続通過車両に対して推定精度を改善できるわけではないと言える。

5. おわりに

本稿では, ステレオマイクを用いて車両検出と車両種別推定を同時に実現する手法を示した。まず, 車両走行音

が 2 台のマイクに到達するまでの時間差を描いたサウンドマップを用いて車両を検出し, 車両の速度及び通過時刻を推定する。その上で, 速度, 通過時刻に基づいて各時刻における通過車両音のマイクへの到達時間差を補正して合成した上で車両音を解析して車両種別を推定する。九州大学伊都キャンパス内の道路で収集した走行音データを用いて初期的評価を行った結果, 推定精度 95.01% で車両種別を推定できることを確認した。

謝辞 本稿で示した研究の一部は, 科研費 (JP15H05708, JP17H01741) の助成で行われた。

参考文献

- [1] 石田繁巳, 三村晃平, 劉 嵩, 田頭茂明, 福田 晃: 路側設置マイクロフォンによる車両カウントシステム, 情報処理学会論文誌, Vol. 58, No. 1, pp. 89–98 (2017).
- [2] 石田繁巳, 梶村順平, 内野雅人, 田頭茂明, 福田 晃: 路側設置マイクロフォンを用いた逐次検出型車両検出システム, 情報処理学会論文誌, Vol. 60, No. 1, pp. 76–86 (2019).
- [3] Buch, N., Cracknell, M., Orwell, J. and Velastin, S. A.: Vehicle Localisation and Classification in Urban CCTV Streams, *Proc. ITS World Congress*, pp. 1–8 (2009).
- [4] Nurhadiyah, A., Hardjono, B., Wibisono, A., Jatmiko, W. and Mursanto, P.: ITS Information Source: Vehicle Speed Measurement Using Camera as Sensor, *Proc. Int. Conf. on Advanced Computer Science and Information Systems (ICACSIS)*, pp. 179–184 (2012).
- [5] Hongliang, B. and Changping, L.: A Hybrid License Plate Extraction Method Based On Edge Statistics and Morphology, *Proc. Int. Conf. Pattern Recognition (ICPR)*, Vol. 2, pp. 831–834 (2004).
- [6] Avery, R. P., Wang, Y. and Rutherford, G. S.: Length-Based Vehicle Classification Using Images from Uncalibrated Video Cameras, *Proc. IEEE Conf. Intelligent Transportation Systems (ITSC)*, pp. 1–6 (2004).
- [7] Aljaafreh, A. and Dong, L.: An Evaluation of Feature Extraction Methods for Vehicle Classification Based On Acoustic Signals, *Proc. IEEE Int. Conf. on Networking, Sensing, and Control*, pp. 570–575 (2010).
- [8] Changjun, Z. and Yuzong, C.: The Research of Vehicle Classification Using SVM and KNN in a Ramp, *Proc. Int. Forum on Computer Science-Technology and Applications*, pp. 391–394 (2009).
- [9] Munich, M. E.: Bayesian Subspace Methods for Acoustic Signature Recognition of Vehicles, *Proc. European Signal Processing Conf. (EUSIPCO)*, pp. 2107–2110 (2004).
- [10] Yang, S. S., Kim, Y. G. and Choi, H.: Vehicle Identification using Wireless Sensor Networks, *Proc. IEEE SoutheastCon*, pp. 41–46 (2007).
- [11] Ishida, S., Kajimura, J., Uchino, M., Tagashira, S. and Fukuda, A.: SAVeD: Acoustic Vehicle Detector with Speed Estimation capable of Sequential Vehicle Detection, *Proc. IEEE Conf. Intelligent Transportation Systems (ITSC)*, pp. 906–912 (2018).
- [12] Fischler, M. A. and Bolles, R. C.: Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography, *Commun. ACM*, Vol. 24, No. 6, pp. 381–395 (1981).