

路側設置振動センサによる交通量推定システムの検討

吉田 誠^{1,a)}大黒 智貴¹日月 伸也¹森山 由美子¹武島 儀忠¹
近藤 裕介¹秋山 真哉²訪諱 博彦^{3,4}安本 慶一³

概要：道路交通量調査は、長年ほとんど人手による観測にて行われておらず、5年に1度の道路交通センサスの最新の調査でも約52%が人の手によるもので、機械化されているのは14%に過ぎない。この理由として機械計測のコストと設置性が課題となっている。そこで、低コストで設置も簡単なピエゾ素子をもついた振動センサを開発し車両通過時の路側に伝わってきた振動信号から特徴量を抽出することで車両の通過判定を行う交通量推定システムの検討を行った。一般的な複数の道路の歩道に振動センサを設置した実験を行い、振動センサから収集した振動音データのみから機械学習アルゴリズムであるSVM(Support Vector Machine)を用いて道路を通過した車両数を推定した結果、雨天を除いて通過車両数をF値0.90以上の精度でカウントすることができた。

キーワード：振動センサ、機械学習、交通量計測、トライフィックカウンタ

1. はじめに

道路交通調査は、整備計画の立案や道路のスムーズな活用によるCO₂の削減を目的として、道路における交通量の実態調査と課題把握のために行われている。日本においては5年に1度、大規模な国土交通省による全国道路・街路交通情勢調査が行われる。この調査は道路交通センサスとよばれ、高速道路、一般国道、都道府県道、一部の指定市の一般市道を観測する交通量調査で、日本全国の様々な環境の道路において計測が行われている。これらの調査のうち人手によらない機械計測による調査については、高速道路においてETC2.0プローブ等を活かした機械計測が活発に行われている一方で、一般道路においては機械計測が普及していない。

「平成27年度全国道路・街路交通情勢調査一般交通量調査結果の概要」[1]によると最新の平成27年の調査でも50%以上は人手による交通量の調査が行われており、機械化をいかにして早急に行うかが国土交通省でも議論されている。図1はこの資料に記載された5年ごとの交通量調査の機械計測の割合を示す図を引用したものであり、これによると人手による交通量計測は、H17年からH27年への10年間をみても13%程度しか減少しておらず、機械化が進んでいないことが見て取れる。この要因として、現状のトライフィックカウンタが高価であることや、装置の規模が大きく、設置と調整に時間と手間がかかる等の課題が挙げられる。このため既設のカメラや監視用途のカメラ(CCTV)等の映像を用いた交通量計測[2],[3]が、既存設備が活用できるため期待されているが、プライバシー対策が必要であることや、夜間で照明の少ない道路における車両検知が困難であるといった課題がある。

また近年、交通モニタリングの研究として、マイクアレ

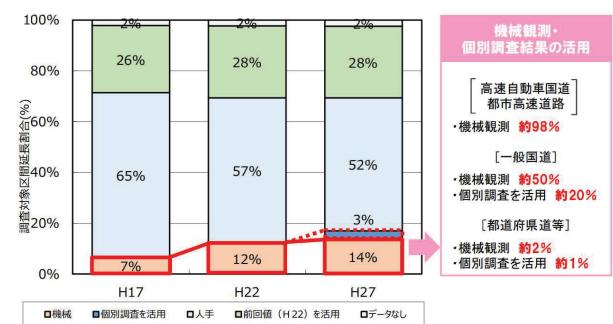


図1 平成27年度全国道路・街路交通情勢調査一般交通量調査結果の概要より抜粋・引用



図2 路側への振動センサ設置イメージ

イを用いて車両走行音を取得し車両の検出を行う研究や、道路上部に、複数のマイクロフォンを水平、垂直方向に配置して、各マイクロフォンに到達する音の時間差からサウンドマップと呼ばれる図を生成する研究[4]、さらに、石田らの研究[5]～[9]ではこれを応用したマイクロフォンを用いた車両検知システムが検討されている。マイクロフォンを用いた方式はコスト面で優れているが、複数のマイクロフォンの距離を調整して道路へ配置する必要があること、また強い風に対するマイクロフォンのダイナミックレンジや環境耐性などの課題もある。本研究では屋内において振動センサを用いて人の位置を特定する研究[10]～[16]を応用し、図2のように車道の路側において車両通過時の

1 オンキヨー株式会社 開発部

2 元・オンキヨー株式会社 開発部

3 奈良先端科学技術大学院大学

4 理化学研究所

a) makoto.yoshida@jp.onkyo.com

振動を検出する振動センサユニットを開発し、これを用いて交通量の機械学習を用いた推定を行うことで、セットアップが容易であり、低コストで、なおかつ堅牢性のある交通量センサシステムを実現する。

以下、本稿の第2章では振動センサシステムの概要と構造および原理、第3章では信号処理と機械学習による交通量推定について、第4章では機械学習による推定の評価結果について述べ、最後に第5章で結果の考察と今後の取り組みについて述べる。

2. 振動センサシステムの概要と構造

2.1 振動センサと車両通過時の振動

一般に道路を車が通過するとき、タイヤと路面の衝突に起因するロードノイズやタイヤと路面の滑りに起因する振動など高周波成分を含んだ振動[17]が発生することが知られている。

本稿ではこの振動が道路から路側帯や歩道まで伝わることを利用して、振動センサを用いて車両通過時の振動をデータとして記録し、得られた複数のデータを用いて機械学習により特徴量を抽出することで、車両の通過状態を判定し交通量の推定を行うことを検討した。振動センサの特徴は、画像を用いないのでプライバシーの問題に配慮できること、また振動センサは原理的に振動源と機械的に接触していればよいため、マイクロフォンのように空間に開かれている必要がなく、空気を伝わる騒音や空気中のダスト等の影響を受けにくいため、トラフィックカウンタとして利用できれば、気象条件に左右されず交通量の機械計測が可能となるメリットがある。

2.2 ピエゾ素子と発生電圧

本研究では振動を感じるためのセンサユニットを構成する基本デバイスとしてピエゾ素子を、図3のような構成で用いる。ピエゾ素子に加えられる加速度を $a [m/s^2]$ 、おもりの質量を $m [kg]$ 、等価圧電定数を d 、ピエゾ素子の静電容量を $C [F]$ とするとピエゾ素子に発生する電圧 $V [V]$ は下記(1)式に示すように素子に加わる振動の加速度 a に比例して発生する。

$$V = \frac{m \cdot a \cdot d}{C} \quad [V] \quad \dots (1)$$

2.3 振動センサユニットの機械的な構成

図4に今回開発したピエゾ素子を用いた振動センサユニットの構造を示す。ユニット筐体は外側筐体と内側筐体の2重構造となっており、同図中拡大して示した内側の構造体の中に質量約300gの固定されていない自由に動くおもりであるフローティングウエイトがピエゾ素子上部にあり、周囲は道路と電気的に絶縁された三角錐の底を持つセンサトレイを設けている。センサトレイはトレイ上部に別の約

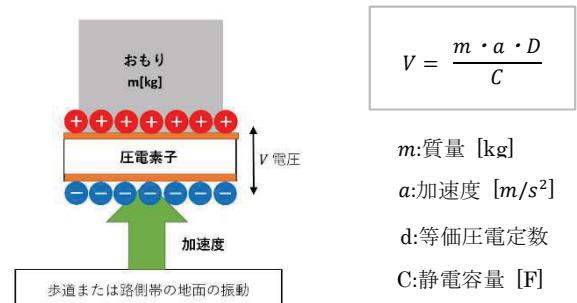


図3 ピエゾ素子に発生する電圧

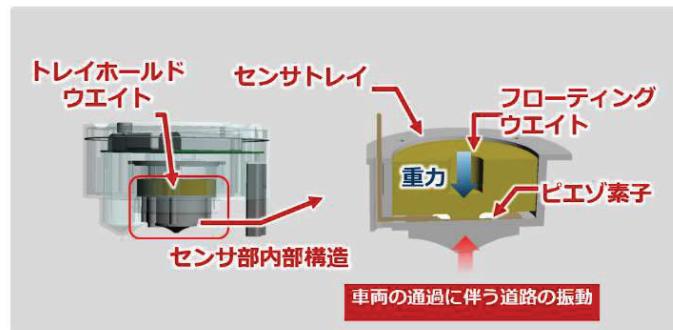


図4 振動センサユニット

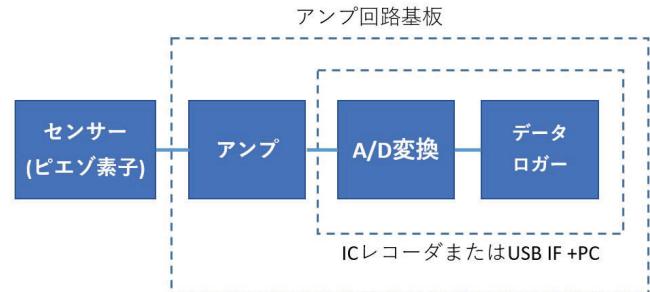


図5 電気回路のシステムブロック図

500gのおもりであるトレイホールドウエイトが載せられておりセンサトレイの地面に対する密着性を高めている。さらにその外周には外側筐体と、地面との角度調整用の足が設けられており、センサトレイの底の三角錐の樹脂が重力に対して垂直となるよう調節できるようになっている。水平を取る際は天面の回路基板に設けられた気泡式の水準器を利用しながら足の長さを調節する。道路を伝わってきた車両による振動がセンサ部へ到来すると、センサトレイは地面に追従して加速度を受け振動するが、フローティングウエイトは、慣性力でその場にとどまろうとする。するとピエゾ素子はセンサ受け皿とフローティングおもりとの間に圧力をうけ、電圧を発生する仕組みとなっている。フローティングウエイトの質量を決めるにあたってはセンサ部分のみの原理モデルを用いて、一定速度でセンサ付近を車で通過させながら質量を可変させる実験を行い、通過時の電圧振幅が最も高い最適な質量を決定した。

2.4 振動センサユニットの電気的な構成

センサユニットシステムのブロック図を図5に示す。

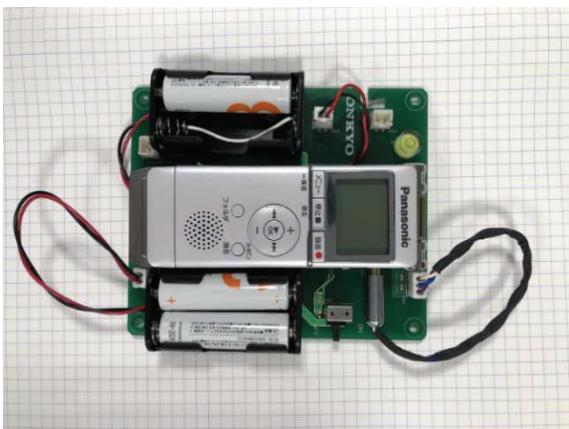


図 6 アンプ回路基板

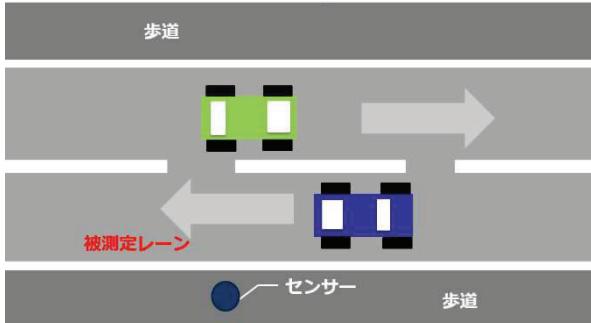


図 7 センサと道路の設置位置関係



図 8 一般道路への設置状況



図 9 正解データ取得用の動画とマーカー

センサユニットシステムの電気回路は4つのブロックから構成されており、まず、振動センサユニットに内蔵されたピエゾ素子(7BB-41-2L0 村田製作所製)が前述のように振

動による圧力を受けて振動を電圧に変える。ピエゾ素子は出力インピーダンスが高いため、後段に設けているソースフォロワ回路を用いたアンプによりインピーダンス変換を行い、その出力信号をUSB Audio I/F またはICレコーダ等でA/D変換してオーディオ信号として録音・記録する。図6に今回開発した、ICレコーダを搭載したアンプ回路基板の写真を示す。

3. 機械学習による交通量推定

3.1 データ取得のためのセンサの設置方法

図7にセンサと道路の設置位置関係の略図を、図8に実験を行った際の一般道路への設置状況を示す。対向二車線の道路の歩道部分に前述のセンサユニットを設置し、センサ横を車が通過する際に発生する振動を取り込む。また、正解データ取得のため図9に示すようにカメラも合わせて設置している。カメラは画面センター位置にマーカーを設け、カメラから見てその真下にセンサが来るようセットアップし、実際に車が通過した状況の動画撮影を行う。なお、実験では一般道路を使用するため、関係する公共機関に許可申請をおこないデータ取得した。

3.2 カメラとセンサ信号の同期方法

カメラと振動センサユニットは個別に録画・録音を行うため、正解データを取得するためには2つのデータの時間同期が必要になる。カメラの前で足踏み等の音の出る動作を行い、カメラとセンサユニット両方にマーカー用のインパルス状のノイズを記録しごとにビデオ編集ソフトで同期を取った。

3.3 取得した振動波形

図10に本センサで取得した、車両通過時の振動波形の一例を示す。なお同図は連続して2台の車両が通過したときの信号波形である。横軸は同期点からの絶対時間を示し、縦軸は振幅を表している。また図11に同じ区間の信号データのスペクトrogramを示す。横軸は同期点からの絶対時間、縦軸は周波数である。図11は図10と同様に2台の車が通過したこと示しており、四角点線で囲った部分が1台分のスペクトrogramとなる。同図のスペクトrogramの分布をみると、車の通過に伴う特有の音色が約5.5[kHz]までの範囲に記録されており、車が通過したことが明確にわかる。実際にヘッドフォンでこの音を確認すると、聴感上でも車の通過が認識できた。また、車の通過の有無にかかわらず定常に約300[Hz]以下の低域のノイズ成分が記録されていることが分かる。これらは現地周辺の鉄道や駅、人の往来や川などがありこれらの振動等の複合による環境起因のノイズと考えられる。さらに図13はバイクが通過したときのスペクトrogramで、丸で囲った特徴的な信号が記録されている。該当箇所のビデオを見ながら振動音をヘッドフォンで確認すると、バイクがエンジンの回転数を下

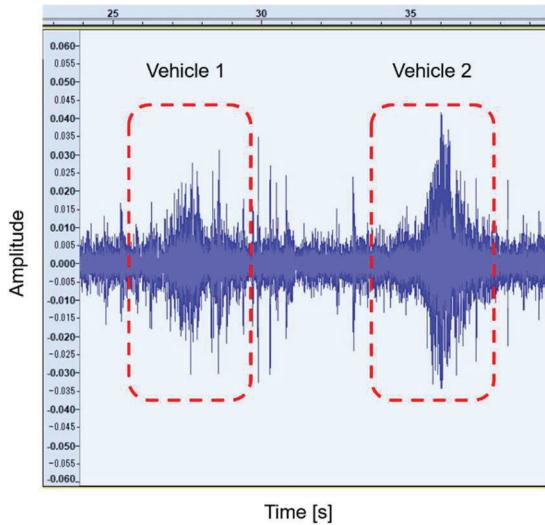


図 10 車両通過時の振動波形

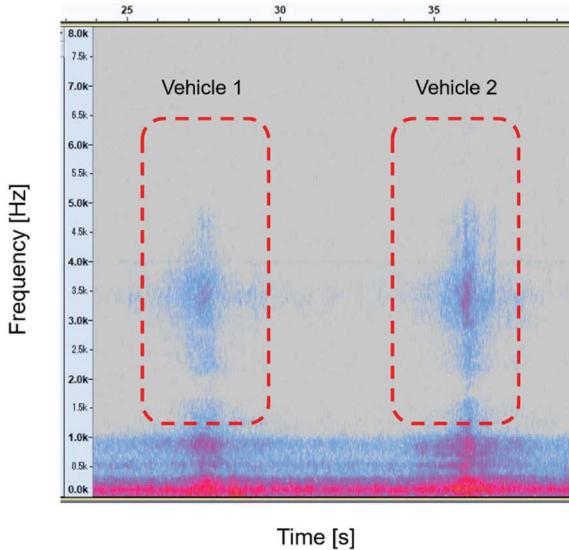


図 11 図 10 と同時刻の振動波形のスペクトログラム

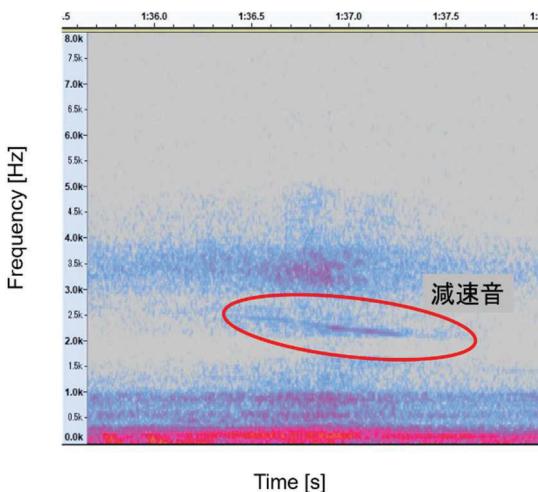


図 12 バイク通過時振動波形のスペクトログラム

げながら通過している事が確認でき、特徴的なエンジン音が振動センサから取得されていた。このように振動音には移動体の特徴を表す特徴量が含まれていることが分かる。

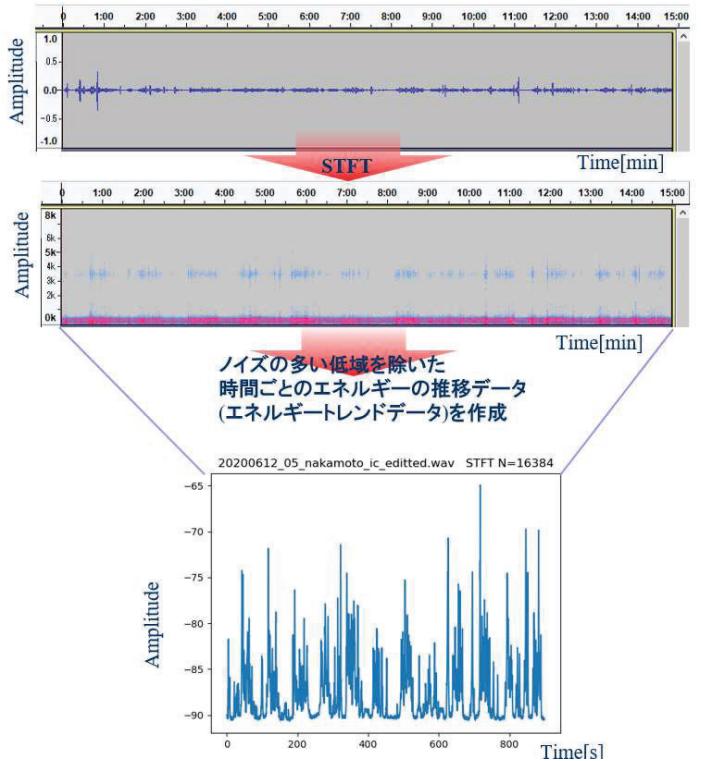


図 13 全録音区間の STFT 後のエネルギートレンドデータ作成

なお、振動音データは、図 8 被測定車線(Measuring Lane)だけではなく対向車線(Opposite Lane)についても、振幅レベルは異なるものの記録されている事が確認できた。

3.4 機械学習のためのデータ作成

次に学習のためのデータを作成する過程について述べる。以下のステップで収録された振動音データから、機械学習のためのデータを作成する。

- 1) 図 13 に示すように、収録した振動音データに対してサンプル数 16384 にて短時間フーリエ変換(STFT)を行う。(図では説明のためスペクトログラムを表示しているが実際は STFT を使用している)
- 2) 次にデータに対して単位時間ごとの周波数軸上の全成分を足し合わせることで、振動のエネルギーの時間的推移データ（以下エネルギートレンドデータと呼ぶ）を作る。このとき 750 Hz 以下の周波数は除外したうえで作成することで、ローカットフィルタと同様の処理を行い、測定環境の定常ノイズ等をカットする。
- 3) 作成したエネルギートレンドデータは、センサが大きな振動を受け取った場合にピークが現れるため、このピークに対して図 14 中の丸印で示したようにマーキング処理を行う。
- 4) エネルギーのピークは車両通過時のノイズなどの影響で、1 台の車両通過による振動信号にもかかわらずピークが 2 つ以上発生する場合がある。この場合 1 台の車に対して、カウントが 2 回以上発生するため、マークを 1 つに減らす処理を行う。具体的には

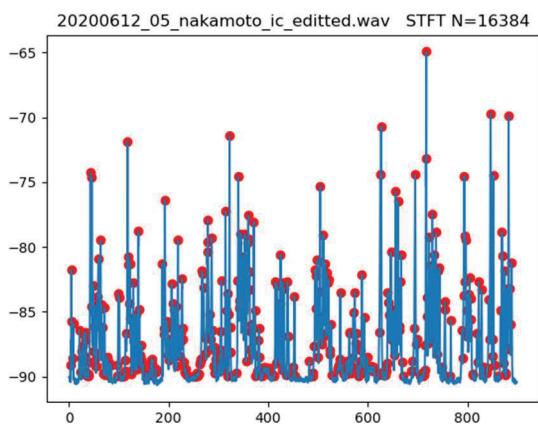


図 14 振動音トータルエネルギーのピークへのマーキング

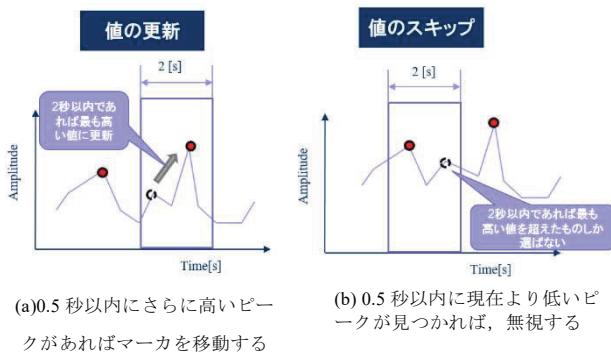


図 15 ダブルカウント防止処理

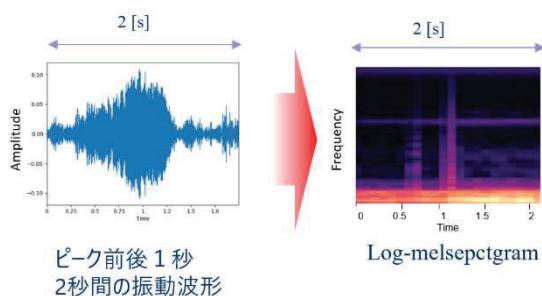


図 16 2秒間の振動波形データの Log-melsepcgram



図 17 ラベリングされた全データのノーマライズ

図 15(a)のように、現在のピークより 0.5 秒以内により高いピークが見つかった場合は、ひとつ後のピークまた、図 15(b)のように現在のピークより低いピー

クが見つかった場合は無視する。なお 0.5 秒の値は通過する車体の速度とサイズ、制限速度、平均的な車間を正解データ用のビデオデータ等を使い経験的に算出した。

- 5) 丸印をつけたピーク部すべての該当時刻について、あらかじめ正解ビデオを確認したうえで作成したラベリングデータと照合する処理をプログラムでおこない、次の正解ラベルを付与する。

- 1 Measuring Lane: 車両が被測定車線を通過した
- 0 Noise: (車両が奥の車線(Opposite Lane)を通過した場合含む)

- 6) マーカーのある時刻を中心として、前後 2 秒間の振動音データを切り出し、1 単位振動音データとして保存する。例として後述の大坂市東成区中本(道路名: 中本)の道路で取り出されたたピークの総数は 808 個で、この場合 808 個の切り出された 2 秒間の録音データが抽出される。
- 7) 2 秒間ずつ切り取られた 1 単位振動音データすべてに対して、Log-melsepcgram を使用して抽出されたデータから周波数ごとの振幅の時間推移としての特徴量を抽出する。図 16 は切り出された 2 秒間の振動データに対する Log-melsepcgram の結果の一例である。Log-melsepcgram のパラメータは経験的に log-mel (80) × FFT セグメント (22) とした。1 データあたりの次元数は $80 \times 22 = 1760$ 次元となる
- 8) 前処理 : 機械学習による分類の前に図 17 のように上記で得られた各データの平均と標準偏差を用いてデータを標準化する処理を行う。

3.5 特徴量の次元削減

前述の 1760 次元の特徴量について、次のようなステップで次元削減を行う。具体的にはランダムフォレストのアルゴリズムにより、下記に示す手順でグリッドサーチを行ったうえで、ベストパラメータにて一度分類を試行し、図 18 のように特徴量の重要度ランキングを確認し、重要度の高いものから平均値以上のものを選択することで次元削減を行った。

- 1) 下記パラメータについて 150 通りのグリッドサーチを行い、ベストパラメータを求める。パラメータの内容と範囲は経験的に設定した。

```

• n_estimators      = [100, 200, 300, 400, 500]
• criterion        = ['gini', 'entropy']
• max_features     = ['auto', 'sqrt', 'log2']
• max_depth         = [4, 5, 6, 7, 8]

```

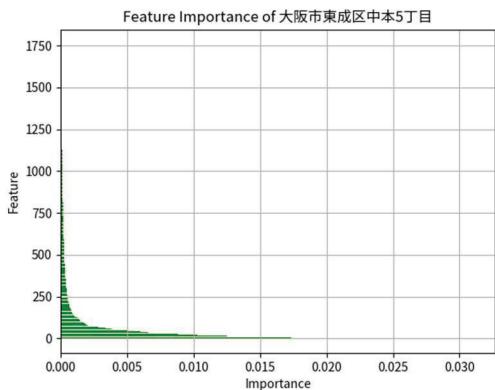


図 18 ランダムフォレストでの特微量の重要度算出例



図 19 特微量の次元削減と分類

- 2) 得られたベストパラメータ用いて一度ランダムフォレストで分類の上、特微量の重要度を算出する。
- 3) 重要度の高いものから平均値以上のものを選択して次元を削減する

3.6 SVM を用いた学習モデル生成による分類

ランダムフォレストで特微量の次元削減を行った後のデータのうち半分をテストデータ、半分を学習データとして分割し SVM を用いて学習モデルを生成した後、テストデータを分類する。このとき SVM を用いた学習モデル生成においてもグリッドサーチを行い、ベストパラメータを求めたうえで分類を行う。グリッドサーチを行ったパラメータは 4 つのカーネルを用いて下記のように設定した。

```
'kernel': ['linear']
'C': [1, 10, 100, 1000],
'gamma': [0.001, 0.0001, 'auto']

'kernel': ['rbf'],
'C': [0.1, 1, 10, 100, 1000],
'gamma': [0.001, 0.0001, 'auto']

'kernel': ['poly'],
'degree': [2, 3, 4],
'C': [0.1, 1, 10, 100, 1000],
'gamma': [0.001, 0.0001, 'auto']
```

```
'kernel': ['sigmoid'],
'C': [0.1, 1, 10, 100, 1000],
'gamma': [0.001, 0.0001, 'auto']
```

以上の一連のプロセスをブロック図にしたものを見図 19 に示す。

3.7 データの評価方法

分類の精度の評価は、以下の値と式を用いて計算した。

- ・ **TP**: テストデータの予測値「1= Measuring Lane」と予測され、実際の正解ラベリングデータが「1= Measuring Lane」であった場合
- ・ **TN**: テストデータの予測値「0= Opposite Lane or Noise」と予測され、実際の正解ラベリングデータが「0= Opposite Lane or Noise」であった場合
- ・ **FP**: テストデータの予測値「1= Measuring Lane」と予測され、実際の正解ラベリングデータ「0= Opposite Lane or Noise」であった場合
- ・ **FN**: テストデータの予測値「0= Opposite Lane or Noise」と予測され実際の正解ラベリングデータ「1= Measuring Lane」であった場合

$$\text{精度(Accuracy)} = \frac{TP + TN}{TP + FP + TN + FN} \quad \dots (2)$$

$$\text{適合率(Precision)} = \frac{TP}{TP + FP} \quad \dots (3)$$

$$\text{再現率(Recall)} = \frac{TP}{TP + FN} \quad \dots (4)$$

$$\text{F値(F - Measure)} = \frac{2 \cdot \text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \quad \dots (5)$$

4. 実道路でのデータ取得と評価結果

市街地の 2 つの道路にて取得したデータを用いて提案システムの評価を行った。取得したデータのうち 1 つの道路については天候の影響を評価するため、天候の異なる条件でデータを取得している。データは各 30 分間の道路の振動データで、道路毎に図 19 に示したアルゴリズムを用いて学習と分類を行った。最初にランダムフォレストにおける 30 分間すべてのデータを用いたグリッドサーチによって表 1 に示すベストパラメータを得た。次にランダムフォレストの特微量ランクイングを用いて特微量の次元削減を行った後、30 分間で取得した振動データのうち半分をテストデータ、半分を学習データとして分割した。さらに SVM において学習用データのみを用いてグリッドサーチを行い表 2 に示すベストパラメータを得た。最後に得られたベストパラメータを用いて学習モデルを生成しテストデータを分類した。結果の推定精度の評価結果を表 3 に示す。この結果

表1 Random Forest のグリッドサーチにおけるベストパラメータ

道路名	n_estimators	criterion	Max_features	Max_depth	F値
中本 (晴)	300	entropy	Auto	8	0.945
高井田 (曇)	100	entropy	Auto	7	0.867
高井田 (雨)	400	entropy	sqrt	8	0.837

表2 SVM のグリッドサーチにおけるベストパラメータ

道路名	kernel	C	gamma	F値
中本 (晴)	rbf	10	auto	0.942
高井田 (曇)	rbf	10	auto	0.907
高井田 (雨)	rbf	100	0.0001	0.867

表3 実道路でのデータ分類の結果

道路名	Accuracy	Precision	Recall	F値
中本 (晴)	0.98	0.93	0.98	0.95
高井田 (曇)	0.97	0.92	0.88	0.90
高井田 (雨)	0.98	0.91	0.86	0.89

より本稿の提案手法にて、天候が雨天以外では通過した車両の通過量を高精度（F値 0.90 以上）で判定可能であることが分かった。また、雨が降った場合でも少し精度は下がるがF値 0.89 と高い精度を保ったまま通過量を計測できることが分かった。ここで、結果のうち精度(Precision)が低い場合は通過する車両の数量を、実際に通過する車両の数よりも多くカウントしていることを表しており、再現率(Recall)が低い場合は、車両を取り逃しており、カウントした車両の数量が実際の数よりも少ないことを意味している。今回の結果からは、「中本」と「高井田」でこれらの値が異なる傾向があることが分った。

5. おわりに

本稿では、振動センサを用いて車両走行時の振動音をとらえて、車両の通過量をカウントする交通量推定システムを提案した。提案したシステムは、振動センサの利点を活かし、簡単に歩道に設置、撤収でき、また低コストかつ最小の情報量取得のみで車両の通過数をカウントできる。

本研究で開発したシステムでは一般道路にてF値 0.90 以上、天候が雨でもF値 0.89 の精度で車両通過量を判定できることを確認した。

ただし、本稿で実測した一般道路は現在 2 か所のみであり、実際の道路は様々な環境が存在することから、今後汎化性の検証のため他の道路での評価の検証が必要であると考えている。特に今回測定した 2 か所において中本よりも高井田の精度が低下している原因について、比較的的道路が混雑していたことや道路の立地が原因である可能性も考えられる。また、他の道路で取得した学習データを用いた車の通過量のカウントの検証も行う必要がある。

また、今回のシステムでは振動音データのピークの検出と、検出されたピーク位置の振動音データの解析の 2 段階で車両通過を推定しているため、車両通過の時の振動音が小さい事などが原因で、前段のピークが検出できなければ、解析まで至らず車両を取り逃してしまう可能性がある。今後はこの点の改善も検討していく。さらに、今回採取した振動音の分析から振動音には、通過する車両の様々な情報が含まれていることが分かり、車両の車種の判別なども合わせて検討していきたい。

参考文献

- 1) Ministry of Land, Infrastructure and Transport, "2015 National Road / Street Traffic Situation Survey Summary of General Traffic Survey Results in Japan" (<https://www.mlit.go.jp/common/001187536.pdf>).
- 2) 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).
- 3) Nurhadiyatna, 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).
- 4) Barbagli, B., Manes, G., Facchini, R. and Manes, A.: Acoustic sensor network for vehicle traffic monitoring, Proc. IEEE Int. Conf. on Advances in Vehicular Systems (VEHICULAR), pp. 1–6 (2012).
- 5) 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).
- 6) Uchino, M., Ishida, S., Kubo, K., Tagashira, S. and Fukuda, A.: Initial Design of Acoustic Vehicle Detector with Wind Noise Suppressor, Proc. Int. Workshop on Pervasive Computing for Vehicular Systems (PerVehicle), pp. 814–819 (2019).
- 7) Ishida, S., Uchino, M., Li, C., Tagashira, S. and Fukuda, A.: Design of Acoustic Vehicle Detector with Steady- Noise Suppression, Proc. IEEE Conf. Intelligent Transportation Systems (ITSC) (2019). (accepted).
- 8) Ishida, S., Mimura, K., Liu, S., Tagashira, S. and Fukuda, A.: Design of Simple Vehicle Counter using Sidewalk Microphones, Proc. ITS EU Congress, EUTP0042, pp. 1–10 (2016).
- 9) Ishida, S., Liu, S., Mimura, K., Tagashira, S. and Fukuda, A.: Design of Acoustic Vehicle Count System using DTW, Proc. ITS World Congress, AP-TP0678, pp.1-10 (2016).
- 10) S.Pan, M.Mirshekari, J.Fagert, C.Ruiz, H.Y.Noh, P.Zhang Area Occupancy Counting Through Sparse Structural Vibration Sensing, IEEE Pervasive Computing 18(1): 28-37 (2019).

- 11) J.Fagert, M.Mirshekari, S.Pan, P.Zhang, H.Y.Noh,Gait health monitoring through footstep-induced floor vibrations: poster abstract. IPSN 2019: 319-320.
- 12) M. Alwan, P. Rajendran, S. Kell, D. Mack, S. Dalal, M. Wolfe, R. Felder, A smart and passive floor-vibration based fall detector for elderly, Proc. 2nd Inform. Commun. Technol., vol. 1, pp. 1003-1007, 2006.
- 13) S.Pan, T.Yu, M.Mirshekari, J.Fagert, A.Bonde, Ole J. Mengshoel, H. Y.Noh, P.Zhang FootprintID: Indoor Pedestrian Identification through Ambient Structural Vibration Sensing. IMWUT 1(3): 89:1-89:31 (2017).
- 14) S.Pan, A.Bonde,J.Jing, L.Zhang,P. Zhang, H.Y.Noh, Boes: building occupancy estimation system using sparse ambient vibration monitoring. In SPIE Smart Structures and Materials+ Nondestructive Evaluation and Health Monitoring, pp. 90611O–90611O. International Society for Optics and Photonics (2014).
- 15) Yukitoshi Kashimoto, Manato Fujimoto, Hirohiko Suwa, Yutaka Arakawa, Keiichi Yasumoto: Floor vibration type estimation with piezo sensor toward indoor positioning system, Proceedings of International Conference on Indoor Positioning and Indoor Navigation (IPIN 2016), pp. 1-6 (2016).
- 16) Shinya Akiyama, Makoto Yoshida, Yumiko Moriyama, Yusuke Kondo, Hirohiko Suwa and Keiichi Yasumoto: Estimation of Walking Direction with Vibration Sensor based on Piezoelectric Device, Proc. PerCom 2020 Workshops, the 4th Intl. Workshop on Pervasive Smart Living Spaces (PerLS 2020) (2020).
- 17) Wu, H., Siegel, M. and Khosla, P.: Vehicle Sound Signature Recognition by Frequency Vector Principal Component Analysis, Proc. IEEE Instrumentation and Measurement Technology Conf. (IMTC), Vol. 1, pp. 429–434 (1998).