

スマートフォンを用いた電気自動車の検知に対する 機械学習によるアプローチ

高木 雅^{1,a)} 川原 圭博^{1,b)} 浅見 徹^{1,c)}

受付日 2016年12月12日, 採録日 2017年7月4日

概要: 電気自動車やハイブリッド車の普及が進むにつれて、その高い静音性ゆえに歩行者が交通事故に遭うリスクが高まりつつある。本稿では、多くの歩行者が持ち歩いているスマートフォンの余剰演算能力を活用し、機械学習により電気自動車やハイブリッド車の接近を高精度に判定する手法を提案する。我々の手法では、電気自動車やハイブリッド車を駆動するためのモータユニットが発する特徴的な高周波音を手がかりとして、歩行者側で車両検知を行うため、車両側にはいっさい特別な設備を必要としない点が特徴である。また、機械学習を用いることで、環境雑音や車種、車速の違いに対する高いロバスト性を実現している。本手法では、スマートフォンの内蔵マイクで録音した環境音を、高速フーリエ変換を用いて周波数領域のエネルギー分布に変換して特徴量とし、4車種、4車速、4環境での実際の走行音データを用いて事前に学習したJ48分類器を用いて、接近車両の有無、車速、車種を推定する。我々の評価実験では、本手法を用いることで、接近車両の有無を92.8%の精度で判定でき、見落とし率は5.2%であった。また、歩行者に近づいてくる車両と遠ざかっていく車両を明確に区別できる点も特筆すべきである。最も早い場合では、最接近の16.5秒前には車両の存在を検知でき、また、複数の車両が同時に存在する場合でも、接近車両の存在を正しく判定できる。

キーワード: 電気自動車, ハイブリッド車, スマートフォン, センシング, 車両検知, 事故予防

A Machine Learning Approach for Electric Vehicle Detection on Smartphones

MASARU TAKAGI^{1,a)} YOSHIHIRO KAWAHARA^{1,b)} TOHRU ASAMI^{1,c)}

Received: December 12, 2016, Accepted: July 4, 2017

Abstract: As electric vehicles (EVs) and hybrid vehicles (HVs) are becoming more and more popular, pedestrians are more at risk of traffic accidents with such quiet vehicles. In this paper, we propose a machine learning approach for EV/HV detection on smartphones carried by pedestrians. Our approach exploits the high-frequency signature sound generated by the motor units in the vehicles and does not require any special equipment on the vehicle side. Our machine learning approach is robust over the ambient noise, vehicle type and vehicle speed. In our approach, we capture the high-frequency sound with a microphone on smartphones and extract the energy distribution in the frequency domain. Then, we determine whether an EV or HV is approaching, the vehicle speed and the vehicle model with a J48 classifier prebuilt with the learning dataset, which includes the actual sounds collected with four EV models driving at four speeds, in four environments. In our evaluation experiments, we can detect EVs in 92.8% accuracy and the false-negative rate was 5.2%. The earliest detection was 16.5 seconds before the vehicle approached the nearest point to the observer. Moreover, even when plural vehicles are approaching to the observer at the same time, our system can detect them correctly.

Keywords: electric vehicle, hybrid vehicle, smartphone, sensing, vehicle detection, accident prevention

¹ 東京大学大学院情報理工学系研究科
Graduate School of Information Science and Technology,
The University of Tokyo, Bunkyo, Tokyo 113–8656, Japan

a) takagi@akg.t.u-tokyo.ac.jp
b) kawahara@akg.t.u-tokyo.ac.jp
c) asami@akg.t.u-tokyo.ac.jp

1. はじめに

ハイブリッド車や電気自動車は、もはや我々の社会において特別な存在ではない。日本では、2015年の新車販売台数の上位25車種のうち、19車種でハイブリッドモデルが提供されており [1]、著しい燃費性能の向上や販売価格の低下にもなっています。ますます人気を獲得している。ハイブリッド車を含めて電気自動車が人気を集める理由は、優れた燃費性能だけでなく高い静粛性にもある。特に15 km/h以下の低速域において、電気自動車の騒音レベルはガソリン車やディーゼル車と比較して著しく優れている [2] (図 1)。優れた静粛性は、自動車の騒音問題に対する直接的な解決策となる一方で、皮肉にも新たな社会問題を引き起こした。すなわち、歩行者や自転車との交通事故の増加である。米国の国家道路交通安全局 (NHTSA) の統計によると、ハイブリッド車はエンジン車と比較して、後退時や駐車時など超低速域での対歩行者事故が2倍多く、対自転車事故の増加も報告されている [3]。また、交通事故の増加だけでなく、犯罪への悪用も問題となっている。具体的には、ハイブリッド車の高い静粛性を利用して被害者の後方から忍び




図 1 ガソリン車とハイブリッド車の騒音レベルの比較。ハイブリッド車は 15 km/h 以下の低速域で特に静粛性に優れている

Fig. 1 Comparison of the noise level between a gasoline-engine vehicle and an HV. HV is especially quiet when driving under 15 km/h [2].

- ① EV/HV quietly approach to pedestrian
- ② Detect a signature sound from EV/HV using smartphone/smart watch
- ③ Show warning messages on wearables




図 2 提案するシステムのコンセプト。歩行者に接近する電気自動車やハイブリッド車を、機械学習を用いてスマートフォン上のアプリケーションで検知する

Fig. 2 The concept of the proposed system. An approaching EV/HV is detected by the application implemented on the user's smartphone. The detection scheme employs the machine learning approach.

寄りバッグを奪い去る、という事件が報告されている [4]。いずれの問題も、歩行者が車両の接近に気づきにくいことが根本的な原因であり、早急な解決策が求められる。

この問題を緩和するため、ほとんどの電気自動車やハイブリッド車には「車両接近警報装置」が備え付けられている。この装置は、車外に設置されたスピーカから警告音を発することで、歩行者に車両の存在を知らせるものである。しかしながら、この装置は3つの重大な問題をかかえている。1点目として、ほとんどの車種の警告音はモータ音を模した高周波音であり、高齢者には聞き取りにくい。2点目として、警告音自体が騒音の原因となり、電気自動車の利点である高い静粛性を台無しにする。3点目として、警報装置は運転者の判断で無効にできるため信頼性が低い。

本研究では、電気自動車やハイブリッド車に搭載されたモータユニットが発する高周波音に着目し、機械学習を用いて車両の接近を検知する手法を提案してきた [5] (図 2)。この高周波音には、駆動系の内部構造に起因して生じるスイッチング雑音が含まれており、これを分析することで走行速度、相対速度といった有用な情報を得られる。また、ドップラー効果による見かけの周波数の変化により、近づく車両と遠ざかる車両を明確に区別できる。我々の評価実験では、これらのスイッチング雑音は都市部の大通りにおいても検知可能なほど明瞭である。人間の聴覚が高周波音に対して比較的鈍感であるのに対して、スマートフォンのような電子機器はこのような高周波音を容易に検知できる。我々の提案する車両検知ロジックはスマートフォン上でリアルタイムに実行できるほどシンプルかつ軽量である。本稿では、これまでの検討 [5] からさらに踏み込んで、実験車両を国産車2車種から輸入車を含む4車種に拡充し、複数車両が同時に存在するシナリオでの性能評価を行う。さらに、成長期に差しかかりつつある Android Wear スマートウォッチへのプロトタイプ実装についても紹介する。

本稿の構成は以下のとおりである。まず2章では、4車種の電気自動車を用いて録音した走行音の特徴を紹介し、ここからどのような情報を得られるかを述べる。次に3章では、我々の提案する車両検知システムの概要と機械学習を用いた学習フェーズにおける録音データの取扱いや特徴量について述べる。4章と5章で我々の提案するシステムの性能を多面的に評価した後、6章で、各種デバイスへの実装の詳細を述べる。7章で関連研究を紹介し、8章で本稿の内容をまとめる。

2. 電気自動車の走行音

2.1 車載モータの駆動メカニズム

電気自動車やハイブリッド車を駆動するためのモータには、タイヤホイールの内側に実装できるほどの小型さと、限られた電力を最大限に活用できる高いエネルギー変換効率が求められる。これらの要件を満たすため、ほとんどの



図 3 計測環境の風景

Fig. 3 Snapshot of the measurement environments.

電気自動車やハイブリッド車は永久磁石同期電動機を採用している。この電動機の回転速度は交流電源の周波数によって制御されるが、電気自動車に搭載されるリチウムイオン電池やニッケル水素電池は直流電源であるため、パルス幅変調 (PWM) で生成した擬似的な正弦波を用いる。この PWM 制御でも高い電力効率が求められるため、絶縁ゲートバイポーラトランジスタ (IGBT) などの半導体スイッチが用いられる。このとき、モータの回転速度によらず、スイッチング周波数は一定であることが多い。この高周波電流がモータ内のコイルを流れて磁界の変動を発生させ、磁界の変動がモータ周辺の金属部品を振動させることで、電気自動車に特有の高周波音が発生する。他に、タイヤと路面との摩擦音や車体の風切音も存在するが、低速域においてはモータからの高周波音が支配的である [6]。

2.2 走行音の録音

電気自動車やハイブリッド車の走行音を分析するため、我々は 4 車種の車両と図 3 に示す 4 つの測定環境で走行音の録音実験を行った。車両については、(1) 日産リーフ (ZE0), (2) トヨタプリウス PHV (ZVW35), (3) BMW i3, (4) 三菱アイミーブ (HA3W), を採用し、実験中は前述の「車両接近警報装置」を無効とした。実験場所については、理想的な計測環境として、(a) 閑静な墓地、(b) 河川公園の駐車場、交通事故の発生しややすい環境として、(c) 閑静な住宅街、(d) 交通量の多い大通り、を採用した。先行研究によると、電気自動車が 30 km/h 以上で走行するときは、タイヤと路面の摩擦音や車体の風切音が支配的となり、ガソリン車と同程度の騒音レベルとなることから、5 km/h, 10 km/h, 20 km/h, 30 km/h の 4 通りで計測を行った [6]。ただし、(d) 交通量の多い大通りでは、交通の妨げとならないよう 30 km/h での計測のみとした。録音機器としては iPod Touch (第 4 世代) と iPhone 5s を採用し、観測者が腰の前で片手保持した状態で内蔵マイクを用いて録音した。サンプリングレートについては広く用いられる 44.1 kHz と 48 kHz の 2 種類とし、録音データは非圧縮の 16 bit リニア PCM 形式 (WAVE 形式) で保存した。車両の通過位置は観測者の前方約 1.5 m の地点としたが、通過する向きは奇数回目と偶数回目で異なる。(d) 交通量の多い大通りを除いて、各計測条件ごとに最低 5 回ずつの計測を行った。

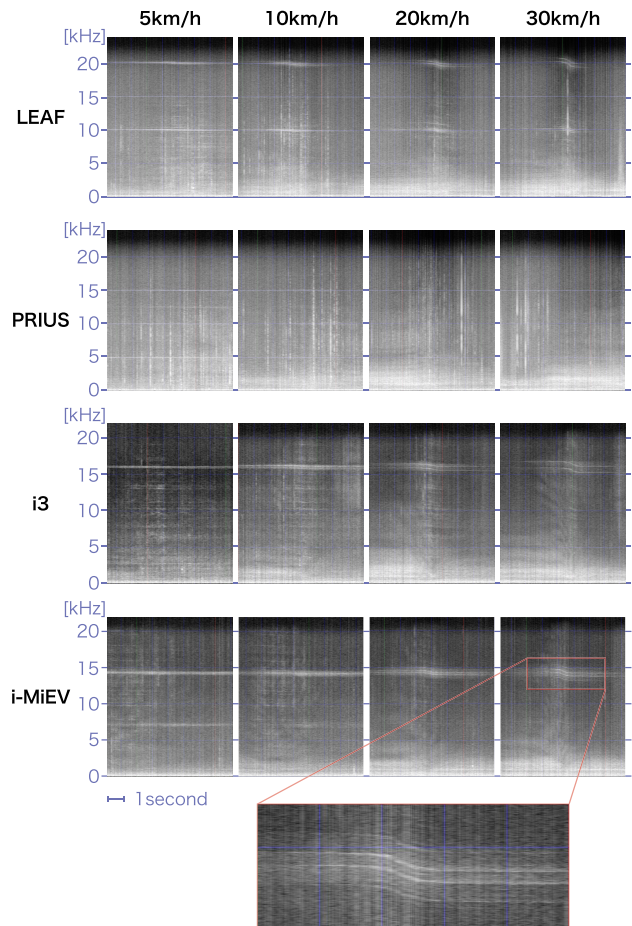


図 4 電気自動車やハイブリッド車の走行音のスペクトログラム。ドップラー効果による見かけの周波数変化を示す S 字カーブが見られる

Fig. 4 Spectrogram of the signature sound from EVs and HVs. S-shaped curves coming from Doppler effect are observed.

2.3 計測結果

図 4 に計測した走行音のスペクトログラムを示す。日産リーフについては、明瞭なスイッチング雑音が 10 kHz 周辺と 20 kHz 周辺に見られる。これとは対照的に、トヨタプリウスのスイッチング雑音は 5 kHz 周辺と 10 kHz 周辺に見られるが不明瞭である。また、BMW i3 では 16 kHz 付近に、三菱アイミーブでは 7 kHz 付近と 14 kHz 付近にスイッチング雑音が見られる。車種によりピーク周波数は異なるが、いずれも 10 kHz 以上の高周波音が主成分である。一方、人間の可聴域はおおむね 20 Hz ~ 20 kHz とされるが、個人差が大きいことに加え、加齢により高周波音に対する感度が低下する。それゆえ、特に高齢者には電気自動車やハイブリッド車の走行音を聞き取ることが難しい。

各スペクトログラムに見られる S 字カーブは、車両の移動にともないドップラー効果で生じた見かけの周波数変化を反映している。ドップラー効果の定義によると、見かけの周波数 f と音源の周波数 f_0 の関係は




図 5 モータの回転速度と各周波数における音圧レベルの関係 [7]
 Fig. 5 Acoustic pressure versus motor speed over the frequency band [7].

$$f = \frac{c^2 f_0}{c^2 - v^2} \left\{ 1 - \frac{v^2 t}{\sqrt{c^2 v^2 t^2 + l^2 (c^2 - v^2)}} \right\} \quad (1)$$

で与えられる．ここで c は音速であり， v は車両の移動速度， l は最接近時の観測者と車両の距離， t は時刻を表す．なお，最接近時の時刻が $t = 0$ である．この関係を利用して，各車速における周波数変化の大きさを事前に予測することは，分類器の作成に用いる特徴量ベクトルの選定に有用である．また，図 5 に示すとおり，永久磁石同期電動機を PWM 制御した際のスペクトルは複数の側波帯に分かれることが知られており，図 4 に示したスペクトログラムでも各 2, 3 本のカーブが見られる [7]．これらをふまえると，電気自動車やハイブリッド車の走行音を分析することで，車速と相対速度を割り出すことが可能である．

3. 車両検知システム

計算資源が限られたスマートフォンやスマートウォッチ上でリアルタイムの車両検知を実現するためには，検知ロジックが十分に軽量である必要がある．一方で，環境雑音や録音機器の違いに対してロバストとするためには，特定の車種の特徴に依存してはならない．さらに，スイッチング雑音に含まれる，車速や相対速度といった情報を有効活用できることが好ましい．これらの要件を満たすため，我々は機械学習によるアプローチを採用した．提案する車両検知システムの概要を図 6 にフローチャートで示す．

3.1 特徴量ベクトル

機械学習の最初のステップとして，我々は 2.2 節で採取した録音データから特徴量ベクトルの抽出を行った．まず，移動幅 100 ms のスライディングウィンドウを設定して音声データを一定量ずつ切り取り，高速フーリエ変換 (FFT)

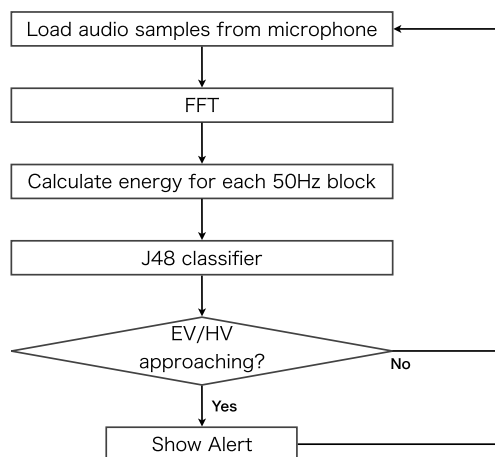


図 6 提案する車両検知システムのフローチャート．分類器は事前に学習データを用いて構築しておく
 Fig. 6 Flowchart of our proposal EV detection scheme. The classifier is trained with the learning dataset in advance.

を用いて周波数領域のエネルギー分布を算出する．次に，50 Hz 刻みでの平均エネルギーを計算し，全周波数帯での平均エネルギーで正規化する．なお，刻み幅を 50 Hz としたのは，以下の 2 つの条件を考慮したためである．1 つ目の条件は，明瞭なスイッチング雑音が見られる 14 kHz 以上の周波数帯において，5 km/h の差をドップラーシフトにより区別できることである．14 kHz の音源が 5 km/h で移動する場合のドップラーシフトは約 57 Hz であることから，刻み幅は 57 Hz 以下に制約される．2 つ目の条件は，スイッチング雑音のピーク周波数が刻みの境界上に位置し，わずかなドップラーシフトでも，上下いずれかの刻みに分類されることである．これにより，近づいてくる車両と遠ざかっていく車両を明確に区別できる．なお，44.1 kHz サンプリングの録音データと 48 kHz サンプリングの録音データを等しく扱うため，ここでは 22 kHz 以下の周波数帯域のみを抽出の対象とした．それゆえ，特徴量ベクトルは 440 次元となる．以降，この 440 次元の特徴量ベクトル 1 つを学習データの 1 インスタンスとして扱う．

3.2 ラベリング

次に，録音データから抽出された特徴量ベクトルに対して，車種と車速を示すラベルを手作業で付与した．車両なしの場合も含めて，“no”，“leaf-5”，“leaf-10”，“leaf-20”，“leaf-30”，“prius-5”，“prius-10”，“prius-20”，“prius-30”，“i3-5”，“i3-10”，“i3-20”，“i3-30”，“imiev-5”，“imiev-10”，“imiev-20”，“imiev-30” の全 17 種類である．車両が近づいてくる部分については，最接近の直近 10 m 分 (5 km/h の場合 7.2 秒分) のみを「車両あり」の学習データとして採用し，それ以前の区間は走行音が不明瞭であることから除外した．また，遠ざかる車両が歩行者を傷つける可能性はないため，車両が遠ざかる部分の録音データについては，




図 7 録音データから学習用データセットを切り出す手順. 走行音の明瞭な最接近の直近 10m 分を「車両あり」の学習データとし, 周波数変化の少ない最接近 1 秒後以降のデータを「車両なし」の学習データとした

Fig. 7 How to pick up the learning dataset from audio data. We labeled the last 10 meters before the nearest point as “Vehicle” because of the distinct sound and labeled the data after the nearest point as “no” excluding the rapid frequency shift within 1 second.

「車両なし」を示す “no” のラベルを付与した (図 7) ただし, ドップラー効果により見かけの周波数が大きく変化する最接近後 1 秒間は除外した. このラベルは, 次節に示す決定木の構築において正解データとして利用される.

3.3 教師あり学習

教師あり学習を行うため, 我々は WEKA というデータマイニングツールを利用した. 分類器には, C4.5 決定木の Java 実装版である J48 決定木を採用した. 学習データには, ほぼ理想的な環境である, (a) 閑静な墓地, (b) 河川公園の駐車場, での録音データのみを使用した. この学習データには, 全 4 車種 (日産リーフ, トヨタプリウス, BMW i3, 三菱アイミーブ) を, 全 4 車速 (5 km/h, 10 km/h, 20 km/h, 30 km/h) の録音データが含まれる. また, 「車両あり」の学習データ数と「車両なし」の学習データ数を均衡させるため, 後者については間引きを行った. 4 章では, スライディングウィンドウ幅を 32,768 サンプル, 間引き率を 1/5 に固定して性能評価を行うが, 5 章で, これらのパラメータの妥当性について検討する.

4. 性能評価

4.1 理想環境シナリオ

まず, 理想的な環境下における単一車種に対する検知性能の評価を行った. 具体的には, 日産リーフを用いて (b) 河川公園の駐車場で録音したデータのみを用いて 10 分割交差検証により判定精度を評価した. 車速は 5 km/h, 10 km/h, 20 km/h, 30 km/h の 4 種類であり, 学習データのインスタンス数は 1,149 個であった. その内訳は, “no” が 321 個, “leaf-5” が 432 個, “leaf-10” が 216 個, “leaf-20” が 108 個, “leaf-30” が 72 個であり, 交差検証における標本群分割はランダムとした.

判定精度は表 1 に示すとおりであり, 接近車両の有無の判定精度は 92.8%であった. 接近車両が存在しないデータ

表 1 理想的な環境下で日産リーフを異なる速度で走行させた場合の検知精度. 接近車両の有無の判定精度は 92.8%であり, 誤検知率と見落とし率 (赤字) はそれぞれ 12.5%, 5.2%であった

Table 1 Confusion matrix for LEAF driving at different speeds in ideal environment. The detection accuracy regardless of vehicle speed was 92.8% and the false positive rate and false negative rate (red letters) were 12.5% and 5.2%, respectively.

Nissan LEAF Parking Lot		Recognition Result				
		no	LEAF 5	LEAF 10	LEAF 20	LEAF 30
Ground Truth	no	87.5%	4.7%	3.7%	2.2%	1.9%
	LEAF 5	2.8%	94.7%	2.3%	0.2%	0.0%
	LEAF 10	6.5%	1.9%	91.2%	0.5%	0.0%
	LEAF 20	6.5%	0.0%	5.6%	85.2%	2.8%
	LEAF 30	13.9%	0.0%	1.4%	2.8%	81.9%




図 8 車両が最接近するまでに 1 度でも車両を正しく検知できた確率. 最接近の 3 秒前までに 95%の車両を検知できている

Fig. 8 Cumulative probability of the true positive detection before the vehicle approaches. Our system can detect 95% of cars 3 seconds before the nearest point.

群に対して「車両あり」と判定した割合を「誤検知率」, 接近車両が存在するデータ群に対して「車両なし」と判定した割合を「見落とし率」と定義すると, 誤検知率は 12.5%, 見落とし率は 5.2%であった. わずかながら隣接する速度区分の誤判定も見受けられるが, 交通事故の防止という目的に照らせば大きな問題ではない.

図 8 は, 車両が最接近するまでに車両を正しく検知できた確率を示したものである. ここでは, 雑音などによる誤検知の影響を除いた正当な評価を行うため, 100 ms 刻みで実行した過去 10 回の判定で 5 回以上「車両あり」と判定した場合のみを「検知」とした. 図 8 によると, 最接近の平均 6.4 秒前には車両を検知できており, 最も早い例では最接近の 13.1 秒前に車両を検知できた. また, 車速が上がるほど検知が遅くなる傾向が見られるものの, 全体では 3 秒前までに 95%以上の車両を検知できた.

4.2 雑音環境シナリオ

次に, 環境雑音を検知性能に及ぼす影響の評価を行った. 具体的には, 日産リーフを用いて, (b) 河川公園の駐車場, (c) 閑静な住宅街, (d) 交通量の多い大通り, の 3カ所で録音したデータを用いて 10 分割交差検証により判定精

表 2 3つの計測環境で日産リーフを走行させた場合の検知精度。接近車両の有無の判定精度は93.2%であり、誤検知率と見落とし率はそれぞれ11.9%、4.9%であった

Table 2 Confusion matrix for 3 different measurement environments. The detection accuracy regardless of vehicle speed was 93.2% and the false positive rate and false negative rate were 11.9% and 4.9%, respectively.

Nissan LEAF 3 Environment		Recognition Result				
		no	LEAF 5	LEAF 10	LEAF 20	LEAF 30
Ground Truth	no	88.1%	4.3%	3.0%	2.1%	2.5%
	LEAF 5	3.8%	94.4%	1.8%	0.0%	0.0%
	LEAF 10	5.6%	4.3%	87.6%	1.5%	1.0%
	LEAF 20	6.1%	0.5%	3.0%	86.4%	4.0%
	LEAF 30	7.1%	0.6%	1.2%	3.0%	88.1%




図 9 車両が最接近するまでに1度でも車両を正しく検知できた確率。大通りでも2秒前までに接近車両を検知できている

Fig. 9 Cumulative probability of the true positive detection before the vehicle approaches. Even on the busy street, our system can detect cars more than 2 seconds before the nearest point.

度を評価した。学習データのインスタンス数は2,115個であった。その内訳は、“no”が561個，“leaf-5”が792個，“leaf-10”が396個，“leaf-20”が198個，“leaf-30”が168個であり、交差検証における標本群分割はランダムとした。

判定精度は表2に示すとおりであり、接近車両の有無の判定精度は93.2%であった。誤検知率は11.9%、見落とし率は4.9%であり、理想環境下とほぼ同じ判定精度を達成している。図9は、車両が最接近するまでに車両を正しく検知できた確率を、計測環境別に集計したものである。最接近の平均5.4秒前には車両を検知でき、最も早い例では最接近の13.6秒前に車両を検知できた。理想環境下と比較すると検知が若干遅れているが、交通量の多い大通りにおける30 km/hの実験データでさえ、最接近の2秒以上前に車両を検知できており、交通事故の防止に十分な性能である。

4.3 車種による違い

さらに、車種の違いが検知性能に及ぼす影響の評価を行った。具体的には、日産リーフ、トヨタプリウス、BMW i3、三菱アイミーブの4車種を用いて、ほぼ理想的な環境である、(a) 閑静な墓地、(b) 河川公園の駐車場、で録音し

表 3 理想的な環境下で4車種を走行させた場合の検知精度。接近車両の有無の判定精度は92.5%であり、誤検知率と見落とし率はそれぞれ7.6%、6.7%であった

Table 3 Confusion matrix for 4 different vehicle models. The detection accuracy regardless of vehicle speed was 92.5% and the false positive rate and false negative rate were 7.6% and 6.7%, respectively.

4 Vehicle Models Semi-ideal Env.		Recognition Result				
		no	LEAF	PRIUS	BMW i3	i-MiEV
Ground Truth	no	92.4%	1.2%	1.5%	2.0%	2.9%
	LEAF	5.8%	92.3%	1.7%	0.1%	0.1%
	PRIUS	7.7%	1.0%	91.2%	0.0%	0.1%
	BMW i3	4.8%	0.3%	0.1%	94.8%	0.0%
	i-MiEV	8.4%	0.0%	0.0%	0.0%	91.6%




図 10 車両が最接近するまでに1度でも車両を正しく検知できた確率。複数車種の学習データを混在させても、問題なく接近車両を検知できている

Fig. 10 Cumulative probability of the true positive detection before the vehicle approaches. Mixed learning dataset can correctly detect multiple models of vehicles.

たデータを用いて10分割交差検証により判定精度を評価した。学習データのインスタンス数は7,066個であった。その内訳は、“no”が3,202個，“leaf”が828個，“prius”が828個，“i3”が1,104個，“imiev”が1,104個であり、交差検証における標本群分割はランダムとした。

判定精度は表3に示すとおりであり、接近車両の有無の判定精度は92.5%であった。誤検知率は7.6%、見落とし率は6.7%であり、単一車種の場合とほぼ同じ判定精度を実現している。また、90%以上の精度で車種を判別できた。図10は、車両が最接近するまでに車両を正しく検知できた確率を、車種別に集計したものである。最接近の平均5.6秒前には車両を検知でき、最も早い例では最接近の16.5秒前に車両を検知できた。以上より、複数車種が混在する場合でも、問題なく接近車両を検知できることが明らかとなった。

4.4 複数車両シナリオ

最後に、複数の車両が同時に走行する2つのシナリオでの評価性能を行った。1つ目は、一方の車両が3秒の間隔において他方の車両を追走するシナリオであり、2つ目は、観測者の前で2台の車両がすれ違うシナリオである。これ

ら2つのシナリオは、BMW i3と三菱アイミーブを用いて、(a) 閑静な墓地で録音を行った。ただし、性能評価に用いる分類器については、理想的な環境における4車種分の録音データで構築した決定木を使用した。このときの学習データの内訳は、“no”が3,202個、“leaf”が828個、“prius”が828個、“i3”が1,104個、“imiev”が1,104個で、合計インスタンス数は7,066個であった。

図11に、複数の車両が同時に接近するシナリオでの検知結果を示す。追走、すれ違いのいずれのシナリオでも、少なくとも1台の車両が接近している場合に検知が集中しており、交通事故防止アプリケーションとして有用である。複数の電気自動車またはハイブリッド車が同時に存在することは珍しくないため、このシナリオで適切な判定をできたことは実用上きわめて重要な成果である。また、最下段に掲載した車両が存在しない場合の録音データに関しては、前述の性能評価結果と同じく90%以上の高い判定精度を実現している。時折見られる誤検知も連続的に発生するものではないため、連続する数フレームの判定結果で多数決をとることで不必要な警報を防ぐことができる。なお、この

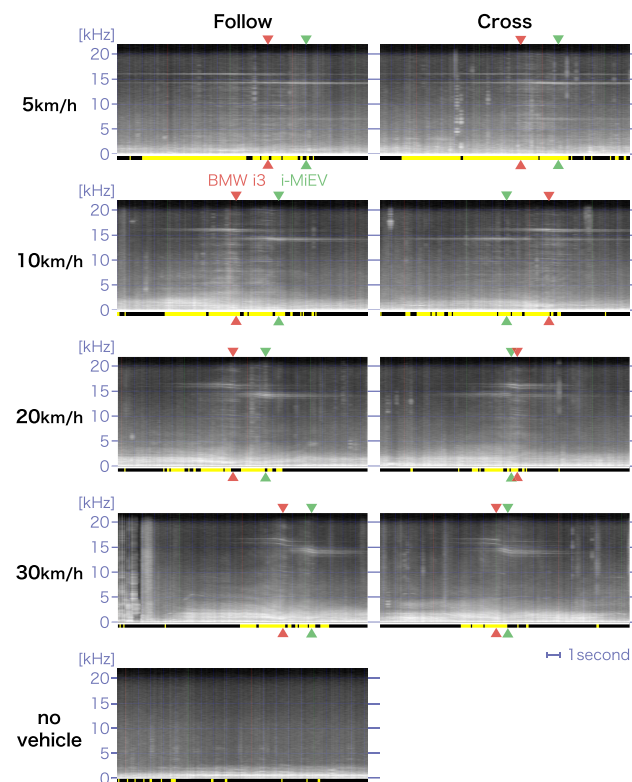


図 11 複数の車両が同時に接近するシナリオでの検知結果。BMW i3 が最接近した時刻を赤印で、三菱アイミーブが最接近した時刻を緑印で、我々のアルゴリズムが接近車両を検知した時間帯を黄線で表示している

Fig. 11 Raw detection result for the multiple vehicle scenarios. The red markers show the time BMW i3 approached, the green markers for Mitsubishi i-MiEV, and the yellow line below the spectrogram shows that our algorithm reported that EV was approaching.

録音データは、(c) 閑静な住宅街において、立ち止まった状態で録音したものである。

5. 検討事項

5.1 見落とし率の低減

交通事故を予防するための車両検知アプリケーションにおいては、誤検知と比較して見落としのコストが非常に大きい。なぜなら、誤検知は歩行者が振り返って車両の有無を確認すれば済むが、見落としは交通事故の原因となりうる。それゆえ、誤検知率を犠牲にしても、見落とし率を減らすことが非常に重要である。3.3節で触れたように、誤検知率と見落とし率のバランスは「車両なし」の間引き率によって調整可能である。

表4に、間引き率を1/2から1/100まで調整したときの判定精度を示す。見落とし率と誤検知率のバランスという観点では、「車両あり」と「車両なし」のデータ数が同程度になる1/5とするのが良い。一方、見落とし率の削減を追求するならば、なるべく「車両なし」のデータを間引くことが望ましい。間引き率を1/100に設定することで、見落とし率を3.2%まで削減できるが、誤検知率は増大する。

5.2 検知精度・遅延・消費電力のバランス

スライディングウィンドウ幅は検知精度を向上させるための重要なパラメータである。4章では、サンプリングによる遅延時間を1秒未満としつつ可能な限り高い周波数解像度を得るため、窓幅を32,768サンプル(=0.683秒)としていたが、この節では、スライディングウィンドウ幅を

表 4 学習データ数が誤検知率と見落とし率に与える影響の評価。間引き率を1/5に設定すると、見落とし率と誤検知率がバランスする。間引き率を1/100に設定することで、見落とし率を3.2%まで削減できるが、誤検知率が犠牲となる

Table 4 How the number of instances affects the false positive rate and the false negative rate. Thinning rate 1/5 balances the false positive rate and the false negative rate. Thinning rate 1/100 can eliminate the false negative rate down to 3.2% at the cost of the false positive rate.

Thinning Rate	Recognition Result		
	no	EV	
= 1/2	no	EV	
Ground	no	96.5%	3.5%
Truth	EV	6.9%	93.1%
no:7744 instances, EV:3864 instances			
= 1/5	no	EV	
Ground	no	92.4%	7.6%
Truth	EV	6.7%	93.3%
no:3202 instances, EV:3864 instances			
= 1/10	no	EV	
Ground	no	85.7%	14.3%
Truth	EV	5.4%	94.6%
no:1674 instances, EV:3864 instances			
= 1/20	no	EV	
Ground	no	78.7%	21.3%
Truth	EV	4.7%	95.3%
no:894 instances, EV:3864 instances			
= 1/50	no	EV	
Ground	no	61.8%	38.2%
Truth	EV	4.0%	96.0%
no:422 instances, EV:3864 instances			
= 1/100	no	EV	
Ground	no	50.9%	49.1%
Truth	EV	3.2%	96.8%
no:269 instances, EV:3864 instances			

短縮する可能性について検討する。

表 5 によると、窓幅が広いほど高精度となる傾向が見られるが、一方で、音声のサンプリングによる遅延時間が長くなる。逆に、窓幅を 1,024 サンプル (= 0.021 秒) まで短縮しても 80%弱の判定精度を維持できるため、前後 5 フレーム (= 0.105 秒) で多数決をとることで、95%弱の判定精度を得られる。

消費電力に関しては、窓幅が十分に狭ければ間欠動作を行う余地が出てくる。ここでは 30 km/h 以下の低速域で移動する電気自動車の検知を目的としていることから、1 秒ごとに車両検知を行えば十分である。仮に、窓幅を 1,024 サンプルに設定して前後 5 フレームで多数決をとる場合、検知システムは 0.1 秒強で動作が完了するため、残りの 0.9 秒弱はスマートフォンの CPU をスリープ状態にして省電力化を図ることができる。

5.3 未知の車種への対応

4 章で検証したとおり、走行音の学習データが与えられた既知の車種については、我々の機械学習によるアプローチで非常に精度良く検知できる。しかしながら、特徴音の異なる未知の車種を検知可能とするためには、当該車種の走行音を学習データとして追加する必要がある。そこで、6 章で紹介する Android アプリケーションに録音機能を付与して、ユーザが未知の車種に遭遇した際の録音データを収集し、2.2 節で録音したデータを含むすべての録音データを用いて決定木を再構築することを考える。多量の録音データを用いる特徴量の抽出および決定木の再構築は、スマートフォン上で行うと計算処理に時間がかかるため、クラウド上で実行することが好ましい。また、特徴量はパラ

表 5 録音データの窓幅と検知精度の関係。窓幅を小さくすると検知精度は悪化する傾向にあるが、窓幅を 1,024 サンプルに設定しても、前後 5 フレームで多数決をとることで、95%弱の判定精度を得られる

Table 5 Relationship between the sliding window size and the detection accuracy. Although the shorter window size gets worse accuracy, we can get 95% accuracy with majority voting of 5 frames even when the window size is 1,024 samples.

Window Size = 32768		Recognition Result		Window Size = 4096		Recognition Result	
		no	EV			no	EV
Ground Truth	no	92.4%	7.6%	Ground Truth	no	85.0%	15.0%
	EV	6.7%	93.3%		EV	15.2%	84.8%

Window Size = 16384		Recognition Result		Window Size = 2048		Recognition Result	
		no	EV			no	EV
Ground Truth	no	90.3%	9.7%	Ground Truth	no	81.9%	18.1%
	EV	9.0%	91.0%		EV	16.5%	83.5%

Window Size = 8192		Recognition Result		Window Size = 1024		Recognition Result	
		no	EV			no	EV
Ground Truth	no	88.3%	11.7%	Ground Truth	no	78.7%	21.3%
	EV	11.2%	88.8%		EV	21.0%	79.0%

メータを変更しない限り不変であるため、1 つの録音データにつき 1 回のみ行えばよく、抽出した特徴量ベクトルをキャッシュしておくことが有効である。クラウド上で分析処理を行うことで、ユーザ間での学習データの共有が可能となり、構築した分類器を全ユーザに配信することで、新車種の登場に迅速に対応できるようになる。

6. 実装

6.1 Android スマートフォン

近年のスマートフォンは、我々の車両検知システムをリアルタイムで実行するのに十分な処理性能を有しており、かつ、ほとんどの歩行者がスマートフォンを所持しているため、十分に活用する余地がある。そこで我々は、提案する車両検知システムを Android アプリケーションとして実装し、住宅街においてデモンストレーション実験を行った。図 12 に、Nexus 4 (2012 年製) で車両検知システムが動作する様子を示す。

このデモンストレーションでは、4 章の環境雑音シナリオで構築した分類器を使用している。図 12 の 2 枚の写真は、車両の最接近 10 秒前と 4 秒前に撮影したものであり、白い日産リーフが接近した 4 秒前の時点で画面に警告が表示されていることが確認できる。

6.2 Android Wear スマートウォッチ

スマートウォッチにはマイクとプロセッサ、ディスプレイが搭載されており、スマートフォンと同様に専用アプリケーションを実行可能である。我々は、提案する車両検知システムを Android Wear アプリケーションとしても実装し、実行速度の評価を行った。最新鋭のスマートフォンと比較するとスマートウォッチの計算資源は貧弱であるが、マイクから入力された音声を実時間処理できた。ここでは、スマートウォッチとして ZenWatch WI500Q を採用し、32,768 サンプル (= 0.683 sec) の音声データを 200 ms 以内に処理できることを確認した。Android Wear SDK を利用すると、通知領域に常駐するアプリケーション




図 12 Android アプリケーションとして実装した我々の車両検知システムのデモンストレーションの様子。白い車 (日産リーフ) が近づくと警告が表示される [5]

Fig. 12 Snapshot of the demonstration of our detection scheme on Android application. The alert shows up when the white car, Nissan LEAF, approaches [5].

を実装可能であり、接近車両を検知した場合にバイブレーションでユーザーに警告を伝えることが可能である。また、文字盤アプリケーションとして実装して常駐させることも可能である。

6.3 Google Glass への通知

一般に、歩行中にスマートフォンを使用することは、周囲への注意が疎かになり交通事故の原因となることから、好ましい行動ではない。この問題を解決するため、我々は前述の Android アプリケーションと連動してユーザーに警告を表示する、Google Glass アプリケーションの実装を行った。すなわち、Android アプリケーションで接近車両を検知した場合に、車両接近を知らせる警告メッセージを Google Glass に表示してユーザーに注意喚起する、というものである。Google Glass アプリケーションの開発に際しては、2種類のアプローチが存在する。1つ目のアプローチは、Glass Development Kit (GDK) を用いる方法で、カメラやマイクといった低レベルのハードウェアにアクセスしつつ、ネイティブアプリを実装できる。しかしながら、計算資源と電池容量の制約がきわめて厳しい Google Glass 上で、長時間にわたって車両検知アプリを実行し続けることは現実的ではない。2つ目のアプローチは、Mirror API を用いる方法で、Web ベースのサービスと連携してプッシュ通知を送信できる。今回は、車両検知の処理をスマートフォン側に任せられることから、Mirror API を用いて通知を表示する部分のみを実装した。

7. 関連研究

本研究は、電気自動車に特有の高周波音に着目し、機械学習を用いて接近車両の検知を行う、我々の知る限りで初めての研究である。本研究の特筆すべき点は、車両側や道路側のインフラ整備をいっさい必要とせず、歩行者が持つスマートフォンでバックグラウンド実行が可能であるため、今すぐにも導入が可能な点にある。この章では、歩行者を交通事故から守るための関連研究を紹介する。これらの提案は、我々の手法と共存が可能であり、併用することで検知精度を向上させることができる可能性がある点に注意されたい。

車両側において周辺の歩行者や障害物を検知する取り組みは、自動車メーカーを含めて幅広く行われており、すでに商用化されたものも存在する [8], [9], [10], [11]。しかしながら、歩行者側の自衛のための車両検知技術は発展途上にある。

これまで、多くの研究者によって提案されてきたのは、近距離無線通信や携帯電話網を利用した車々間（歩車間）通信システムであり、自動車や歩行者が位置情報を交換することで、互いの接近を検知するものである [12], [13]。これらのシステムは信頼性に優れている反面、車両側と歩

行者側の双方に専用機器の設置が必要であり、残念ながら普及には程遠い状況である。言い換えれば、車両側の協力なくしては、歩行者は自分の身を守ることができないという重大な欠点をかかえている。

車両側の設備に頼らない手法としては、画像情報から車両を検知する手法が多く提案されている [14], [15]。Sivaraman らは、動画中の車両を認識し、その移動を追跡する汎用的な学習フレームワークを提案している [16]。また、The cyber-physical bike は自転車の認識に特化したフレームワークである [17]。さらに、Wang らは、スマートフォンのカメラを用いて接近車両をリアルタイムに検知する WalkSafe を提案している [18]。画像処理によるアプローチの長所は、車両の移動方向を推定することで衝突のリスクを評価できる点にある。一方で、短所としては、歩行者がつねにカメラの向きを意識し続ける必要がある点や、カメラの消費電力が非常に大きい点があげられる。

音声情報から接近車両を検知するというアプローチ自体は、特段新しいわけではない。Tsuzuki らは、LVQ ニューラルネットワークを用いた、スマートフォン向けの車両検知システムを提案している [19]。しかし、この手法は 30 km/h 以上で走行するガソリン車を対象としており、より静粛性の高い電気自動車は検知できないと推定される。加えて、ニューラルネットワークを用いることから、スマートウォッチのような機器には計算負荷が大きい。判定精度に関しては、Tsuzuki らの手法では、30 km/h で走行する車両を最接近の平均 4.3 秒前に検知可能であるが、我々の手法では、同様の状況下で平均 6.5 秒前に検知可能である。

8. まとめ

本稿では、電気自動車やハイブリッド車に特有の高周波音を手がかりとして、機械学習で接近車両を検知する手法を紹介した。この高周波音は、車両を駆動するモータの回転速度を制御するために用いられる、PWM 制御のスイッチング操作に起因するものであり、我々の手法はほとんどの商用車に適用可能である。本手法では、正規化した 50 Hz 刻みの周波数分布を特徴量として、機械学習により分類器を生成する。我々の評価実験では、接近する車両のみを選択的に検知するだけでなく、車速や車種も区別可能であることが示された。また、環境雑音の違いや車種の違いに対しても十分にロバストであった。理想的な環境における車両の有無の判定精度は 92.8% であり、見落とし率は 5.2% であった。また、歩行者に近づいてくる車両と遠ざかっていく車両を明確に区別できる点も特筆すべきである。最も早い場合では、最接近の 16.5 秒前には車両の存在を検知可能であった。

また、我々はこの車両検知システムを Android アプリケーション、Android Wear アプリケーションとして実装し、Google Glass に警告を表示する連携システムを実装し

た。計算負荷は十分に小さく、スマートフォンやスマートウォッチ上でも十分にリアルタイム実行が可能であった。

本システムは、車両側や道路側の特別なインフラを必要としないため、歩行者が自衛のために有用だと判断すれば、今すぐにも導入が可能である。また、既存手法とは異なりカメラやGPSといった電力消費の激しいデバイスを使用しないことから、電池容量の限られたモバイルデバイスやウェアラブルデバイスに適したシステムである。

参考文献

[1] 一般社団法人日本自動車販売協会連合会：新車乗用車販売台数月別ランキング，入手先 (<http://www.jada.or.jp/contents/data/ranking.html>).

[2] Commission on measures for quietness of hybrid vehicles: Report on measures for quietness of hybrid vehicles, Government report of Ministry of Land, Infrastructure, Transport and Tourism (2010).

[3] NHTSA: Incidence of pedestrian and bicyclist crashes by hybrid electric passenger vehicles, NHTSA Tech. Rep., DOT HS 811 204 (2009).

[4] 朝日新聞：静かなプリウスでひったくり 被害者「走行音聞こえず」，朝日新聞 (2010).

[5] Takagi, M., Fujimoto, K., Kawahara, Y. and Asami, T.: Detecting Hybrid and Electric Vehicles Using a Smartphone, *Proc. 2014 ACM International Joint Conference on Pervasive and Ubiquitous Computing, UbiComp '14*, New York, NY, USA, ACM, pp.267-275 (online), DOI: 10.1145/2632048.2632088 (2014).

[6] University of California: Hybrid Cars Are Harder to Hear, University of California, Riverside, Newsroom (2008), available from (<http://newsroom.ucr.edu/news-item.html?action=page&id=1803>).

[7] Cassat, A., Espanet, C., Coleman, R., Leleu, E., Burdet, L., Torregrossa, D., M'Boua, J. and Miraoui, A.: Forces and vibrations analysis in industrial PM motors having concentric windings, *IEEE Energy Conversion Congress and Exposition (ECCE)*, pp.2755-2762 (online), DOI: 10.1109/ECCE.2010.5618070 (2010).

[8] Gandhi, T. and Trivedi, M.: Pedestrian Protection Systems: Issues, Survey, and Challenges, *IEEE Trans. Intelligent Transportation Systems*, Vol.8, No.3, pp.413-430 (online), DOI: 10.1109/TITS.2007.903444 (2007).

[9] Bu, F. and Chan, C.Y.: Pedestrian detection in transit bus application: Sensing technologies and safety solutions, *Proc. IEEE Intelligent Vehicles Symposium*, pp.100-105 (online), DOI: 10.1109/IVS.2005.1505085 (2005).

[10] Daimler: Mercedes-Benz TechCenter: Night View Assist Plus, Mercedes-Benz, Technologien, available from (<http://techcenter.mercedes-benz.com/en/night.view-plus.with.spotlight/detail.html>).

[11] Toyota: Night View, Toyota Global Site, Technology File, Active Safety, available from (http://www.toyota-global.com/innovation/safety.technology/safety.technology/technology_file/active/night.view.html).

[12] David, K. and Flach, A.: CAR-2-X and Pedestrian Safety, *IEEE Vehicular Technology Magazine*, Vol.5, No.1, pp.70-76 (online), DOI: 10.1109/MVT.2009.935536 (2010).

[13] Oki Electric Industry Co., L.: OKI Succeeds in Trial Production of World's First "Safety Mobile Phone" to

Improve Pedestrian Safety, Press release (2007).

[14] Feris, R., Siddiquie, B., Zhai, Y., Petterson, J., Brown, L. and Pankanti, S.: Attribute-based Vehicle Search in Crowded Surveillance Videos, *Proc. 1st ACM International Conference on Multimedia Retrieval, ICMR '11*, New York, NY, USA, ACM, pp.18:1-18:8 (online), DOI: 10.1145/1991996.1992014 (2011).

[15] He, D., Lang, C., Feng, S., Du, X. and Zhang, C.: Vehicle Detection and Classification Based on Convolutional Neural Network, *Proc. 7th International Conference on Internet Multimedia Computing and Service, ICIMCS '15*, New York, NY, USA, ACM, pp.3:1-3:5 (online), DOI: 10.1145/2808492.2808495 (2015).

[16] Sivaraman, S. and Trivedi, M.: A General Active-Learning Framework for On-Road Vehicle Recognition and Tracking, *IEEE Trans. Intelligent Transportation Systems*, Vol.11, No.2, pp.267-276 (online), DOI: 10.1109/TITS.2010.2040177 (2010).

[17] Smaldone, S., Tonde, C., Ananthanarayanan, V.K., Elgammal, A. and Iftode, L.: The Cyber-physical Bike: A Step Towards Safer Green Transportation, *Proc. 12th Workshop on Mobile Computing Systems and Applications, HotMobile '11*, New York, NY, USA, ACM, pp.56-61 (online), DOI: 10.1145/2184489.2184502 (2011).

[18] Wang, T., Cardone, G., Corradi, A., Torresani, L. and Campbell, A.T.: WalkSafe: A Pedestrian Safety App for Mobile Phone Users Who Walk and Talk While Crossing Roads, *Proc. 12th Workshop on Mobile Computing Systems and Applications, HotMobile '12*, New York, NY, USA, ACM, pp.5:1-5:6 (online), DOI: 10.1145/2162081.2162089 (2012).

[19] Tsuzuki, H., Kugler, M., Kuroyanagi, S. and Iwata, A.: A Novel Approach for Sound Approaching Detection, *Neural Information Processing, Models and Applications*, Wong, K., Mendis, B. and Bouzerdoum, A., (Eds.), Lecture Notes in Computer Science, Vol.6444, pp.407-414, Springer Berlin Heidelberg (online), DOI: 10.1007/978-3-642-17534-3_50 (2010).



高木 雅 (学生会員)

1990年生。2013年東京大学工学部電子情報工学科卒業。2015年同大学大学院修士課程修了，同博士課程に在学中。スマートフォンを用いたセンシング技術の適用領域拡大に関する研究に従事。電子情報通信学会会員。



川原 圭博 (正会員)

1977年生。2000年東京大学工学部電子情報工学科卒業。2002年同大学大学院修士課程修了，2005年同博士課程修了。博士（情報理工学）。2005年同大学院情報理工学系研究助手。助教を経て，2010年同講師，2013年同准教授。2011～2013年ジョージア工科大学客員研究員およびMIT Media Lab客員教員を兼任。2014年AgIC株式会社技術アドバイザー。電子情報通信学会，IEEE，ACM各会員。



浅見 徹 (正会員)

1952年生。1974年京都大学工学部電子情報工学科卒業。1976年同大学大学院修士課程修了。同年国際電信電話株式会社（KDDI）に入社。UNIX通信，ネットワーク障害診断，xDSLの実証実験等に従事。博士（情報理工学）。2001年KDDI研究所代表取締役所長。2006年東京大学教授。電子情報通信学会，IEEE，ACM各会員。