Time-of-flight 測距センサアレイと機械学習を用いた運転手の姿勢識別

山 賀 瑛 斗*・浅 野 直 生*

杉 浦 裕 太*・杉 本 麻 樹*

Driving Posture Classification with Time-of-flight Sensor Arrays and Machine Learning

Eito YAMAGA*, Nao ASANO*,
Yuta SUGIURA* and Maki SUGIMOTO*

In this paper, we propose a method to classify the posture of a driver in a vehicle using time-of-flight (ToF) range sensors and machine learning. Conventionally, to estimate the posture of a driver, there are methods using RGB or depth cameras around the driving seat. However, previous estimation methods needed to handle large data from the cameras, and privacy can be an issue in such a camera based system. In this study, we propose a range sensor based driving posture classification method. We design a sensing system which consists of range sensing modules around the driving seat inside a vehicle, and the system identifies the posture of the driver by distributions of the sensor values. We installed the system into a vehicle and verified the feasibility of the proposed method.

Key Words: driving posture classification, embedded optical sensors, machine learning

1. はじめに

日常生活において自動車は移動手段の1つとして広く利用されているが、その一方で、自動車事故も後を絶たない。そのため、安全運転を支援するシステムが多く提案されてきた^{1), 2)}。安全運転を実現するには運転手が周囲に気を配れるような正しい姿勢で運転をする必要がある。自動車事故の要因の1つとしてながら運転や漫然運転(顔は前方を向いていながら、ぼんやりと考えごとをしているような運転に集中していない状態)が挙げられる^{3), 4)}が、そのような状態では極端な姿勢が観察できると報告されている⁵⁾。また、搭乗者のためのエアバッグなどの安全装置の制御が搭乗者に合わせて適切になされていないために大きな怪我をするという事故が起きるケースがあることも知られている^{6), 7)}。システムが運転手の姿勢や状態を識別することは、安全な運転状態の検知や安全装置の制御のためにも有用であると考えられる。

また、自動車の自動運転技術が徐々に実用化され、将来的には多くの車に自動運転の機能が搭載されることが考えられる。2016年に定義された自動運転レベルでは0から5までのレベルが設定された⁸⁾。緊急時に人間の運転手が運転をするとき以外はシステムが自動運転を行なうレベル3や、人間の運

転手を必要とせず特定の条件下で自動運転を行なうレベル4のシステムの実用化が期待されている。レベル3のシステムが自動運転モードからマニュアルモードの切り替えを行なう際、システムが運転手の手動運転に対する準備状況を把握する上で、姿勢に基づく状態推定は実用的であると考えられる。また、自動運転中に万が一事故が起きそうになった場合、システムは搭乗者の姿勢を認識できれば、搭乗者に可能な限り被害が及ばない方向に進むといった運転操作が可能と期待される。運転の大部分をシステムが担う場合には、運転手の姿勢から運転手の気分を汲みとった運転を実行するようなユーザエクスペリエンスの高い自動運転も将来的に求められると考える。以上のことから、自動運転が普及した際に、システムが運転手の姿勢を識別する技術は有用と考えられる。

運転手の運転時の状態をシステムが識別する手法は従来から提案されている^{9)~16)}。カメラの画像を用いて識別する手法や、深度カメラの深度画像を用いる手法、慣性センサを用いる手法などが挙げられる。しかし、それらは計算負荷やユーザへの装着負荷が大きく、プライバシーに配慮しきれていない場合があることが課題である。また、車内という広くはないデザインが重視された空間にセンサを設置するため、小型で組み込みやすいセンサが適切である。

そこで本研究ではそれらの条件を満たす測距センサの1つであるTime of Flight (ToF) センサ(**Fig. 1**)を車輛のコックピットに複数配置することで運転手の姿勢を識別する手法を検討する。姿勢ごとに特徴をもつように配置した複数のToFセンサで距離の分布を計測することで、全体のデータ量が小

* 慶應義塾大学大学院理工学研究科 横浜市港北区日吉 3-14-1

* Graduate School of Science and Technology, Keio University, 3-14-1 Hiyoshi, Kohoku-ku, Yokohama

(Received February 6, 2019)

(Revised June 13, 2019)

Fig. 1 ToF sensor array: 4 ToF sensors are aligned in a 3D printed case as a sensing module

Fig. 2 Concept of our proposed method: ToF sensor value distribution can be changed by driving postures

さく、計算負荷が小さい識別システムを構築することができると考えられる。低次元の距離情報を姿勢識別に利用するため、画像情報を用いる方法と比較してプライバシーに敏感なユーザにも配慮しやすい。

本研究で使用する ToF センサは計測対象に合わせて配置を変更することができ、車内に組み込みやすいといった特徴をもつ。こうした複数の ToF センサを車輻に設置し、得られた距離情報から、機械学習を用いて運転手の姿勢を識別する方法 (Fig. 2) を提案する。

2. 関連研究

ユーザの姿勢や状態識別を行なう方法として、カメラの画像を用いて識別する手法、深度カメラの深度画像を用いる手法、慣性センサを用いる手法などが挙げられる。本章ではそれぞれの手法に関する研究について述べる。

画像を用いた識別の手法として主流なのが深層学習を利用したものである。Wei らは、全層畳み込みニューラルネットワークを用いて、身体の部分ごとに Confidence Maps を生成し、姿勢識別を行なっている⁹⁾。このネットワーク構造ではリアルタイムな識別が可能となっており、人の姿勢のデー

タセットによっては 80~90% と良好な検出率を示している。また、Yan らは、畳み込みニューラルネットワークを用いて車載カメラの画像情報から運転手の姿勢を識別する手法を提案している¹⁰⁾。ユーザの手の位置に着目し、4 種類の姿勢を約 95~99% の精度で識別している。

こうした画像処理の研究での識別対象としては、ながら運転の検出を狙いとして Southeast University Distracted Driver Dataset を対象とした研究¹¹⁾が知られている。「ハンドルを握っている姿勢」、「シフトレバーを操作している姿勢」、「ケーキを食べている姿勢」、「携帯電話で会話している姿勢」といった 4 姿勢の画像を識別対象としている。また、姿勢数を増やした多数のデータセットが公開されており、一例としては、「飲料を飲む姿勢」、「ラジオを調整する姿勢」、「安全姿勢での運転」、...,「左右の手で携帯電話をもちながらメッセージングする姿勢」など、安全な運転姿勢とそれ以外のながら運転などを含む 10 姿勢の画像を識別対象とした研究¹²⁾が行なわれている。

以上のように、画像処理技術を用いることで高い精度で運転手の姿勢を識別することが行なわれている。しかし、これらの技術を利用するには畳み込みニューラルネットワークが必要であるため計算負荷が大きい点、そして車内にカメラを設置する必要がありプライバシーへの配慮が小さいと捉えられかねない点がある。カメラが設置されている自動車は車輻に搭載されたシステムにてカメラの映像処理が完結するように設計されているため、カメラ映像が外部に流出することを防ぐことができているが、モノがインターネットにつながる IoT 製品が発展している現代で、いずれネットワークにつながるであろう自動車の中にカメラが設置されていることに不安を感じるユーザもいると考えられる。

深度画像を用いた識別でも深層学習が利用されている。Haque らは畳み込みニューラルネットワークと再帰型ニューラルネットワークを用いて深度画像から姿勢識別を行なっている¹³⁾。検出率は 75~99% となっているが、処理に 1.7 秒と時間がかかっている。また、Martin らは Decision Forests を利用し、深度画像から車内の運転手の姿勢識別をする手法を提案している¹⁴⁾。身体の部分ごとにラベリングを行ない、その後クラスタリングを行ない姿勢識別をしている。19 種類の姿勢を 20~51 fps で識別しており、実際の身体的位置と識別位置との誤差は 0.02~0.5 m となっている。以上のように、深層学習やランダムフォレストを用いた技術から運転手の姿勢を識別している。しかし、先述の画像を用いた姿勢識別と同様に画像データは情報量が大きいため計算負荷が大きい傾向がある。

加速度センサや慣性センサを用いた研究ではセンサ値から姿勢を計測している事例がある^{15), 16)}。センサは小型であるが、ユーザに装着しなければならないためユーザに負荷がかかる。また、長時間の使用ではセンサデータにセンサ出力のドリフトの影響が現れたり、環境ノイズの影響が含まれたりするため、識別精度が低下するといった課題がある。

3. 提案手法

本章では、本研究で提案する複数の測距センサによる識別手法について説明する。複数のセンサを配置し、センサ値を取得することで人の身体の一部の姿勢識別が行なわれている。Natsukiらは物体にセンサアレイを設置し、その物体を掴む手の把持姿勢を計測するシステムを提案している¹⁷⁾。測定対象の形が未知のものでなければ、測定対象の一部の情報から測定対象の姿勢を識別可能だと考えられる。そこで、われわれは車内のコックピットに測距センサを複数配置することで搭乗者の姿勢識別が行なえるのではないかと考えた。自由な姿勢がとれる屋外とは異なり、自動車内は屋外と比べ狭く、搭乗者は基本的に座った姿勢に限定されるため、姿勢の種類が絞られる。姿勢に応じた手や頭などの位置や体型の違いに応じて車内のコックピット周辺に搭乗者に向けて配置された各測距センサから得られる距離情報に変化が起きるため、そのセンサ値の変化から識別が可能ではないかと考えられる。本研究では、測距センサには小型で運転席をカバーできる測距可能範囲をもつToFセンサとして、STMicroelectronics社VL53L0Xを採用した。VL53L0Xは幅4.4mm、奥行2.4mm、高さ1.0mmとコンパクトなサイズで、分解能は1mm、測定可能範囲が0~2000mm、視野角が25度となっている。用意した複数のセンサでそれぞれ距離情報を取得し、教師あり機械学習の1つであるSupport Vector Machine (SVM)を用いることで、取得したセンサ値から運転手の姿勢を識別する。

4. 評価

本章では、提案手法の有効性を検証するために行なった実験について述べる。本研究では、関連研究での識別対象となっている姿勢を参考にして、通常時、右折時、左折時といった基本的な運転姿勢に付加して、漫然運転につながる前傾姿勢やあくびをしているような顔に手を当てる姿勢、ながら運転につながるスマートフォンの利用や、コンソール操作、運転席に落としたものを拾う姿勢などを加えたTable 1に示す9個の姿勢を識別対象として姿勢の識別が行なえるかを検証することとした。また、搭乗者には、交通事故の際に安全装置の制御が適切に行なわれず怪我をする場合がある子供や肥満体など、体型が大きく異なる者も含まれる可能性がある。こうしたTable 2に示すクラスについても識別可能か検証を行なうこととした。

なお、本研究は、慶應義塾大学研究倫理委員会が定める研究倫理要綱に則って実施を行なった。

4.1 室内実験

まず、初期検討として、研究室内に車輛のコックピットを模した環境を作成し、測定を行なった。コックピットのハンドル周辺に16個のToFセンサを設置した(Fig. 3)。実験参加者1名に運転時の姿勢の一覧Table 1およびFig. 4に示す姿勢を示す9種類の運転姿勢をとるように依頼し、離散的に運転時の姿勢ごとにセンサ値を繰り返し取得した。実験参

Table 1 Driving posture classes

No.	Class
1	Regular Driving
2	Right Turn
3	Left Turn
4	Leaning Forward
5	Hands-free Driving
6	Single Hand Driving (Left Hand Touches Cheek)
7	Operating Smartphone
8	Operating Car Console
9	Picking Up

Table 2 Additional classes

No.	Class
10	Child
11	Obesity
12	No Driver

(a)

(b)

Fig. 3 Early experimental setup in our laboratory: 16 ToF sensors are attached around the steering

Fig. 4 Snapshots of driving postures

加者は9種類の姿勢を順番にとり、1つの姿勢について100回センサ値を取得する試行を計4試行繰り返した。実験参加者への姿勢の依頼は口頭で「通常の運転姿勢をとってください」といった形式で、姿勢の指示をしており、具体的な関節角などの指示は行っていない。

取得したデータに対して機械学習による姿勢の切り分けが可能かを判断するために姿勢ごとの各センサ値の傾向を平均値と標準偏差によって確認し、主成分分析を行なった (Fig. 5, Fig. 6)。それらの結果から大まかな姿勢の分類が可能と考え、その後、機械学習のSVMを利用し、RBFカーネル ($C = 10$, $\text{degree} = 3$, $\text{gamma} = 0.1$) を用いて訓練を行なった。SVMのパラメータは得られたデータの10%をもとに決定した。取得したデータは標準化によって特徴量のスケールリングを行ない、機械学習によって姿勢識別の識別率を検証した。

実験参加者のデータ内で13分割の交差検証を行なった際の識別率は0.934となった。ToFセンサを車輻のcockピットを模した環境に複数配置することで、個人の姿勢を90%以上の精度で識別できており、提案手法の妥当性が確認できた。

つぎの段階である車輻を用いた実験においては、日光やエンジンの揺れといった外乱が識別精度に影響を与えることが懸念される。また、複数の実験参加者での測定となるため、実験参加者によって手や頭の位置に変化があると考えられる。識別精度を維持できるよう、センサの位置をハンドル周辺部だけでなく頭上などにも配置し、変化に対応できるようセンサの数を増やすことで、外乱が識別結果に影響を与えづらく、

実験参加者の姿勢の差に対応できるようなセンサ配置を目指すことにした。

4.2 車輻実験

初期検討の後、先述のように配置を変更すると共にセンサ数を増やした実装として、実際の車輻のcockピット周辺に24個のToFセンサを配置したものを準備して計測を行なった (Fig. 7~Fig. 9)。センサの設置場所は直接日光が当たりにくく、エンジンの振動が顕著には伝わっていない場所とし、前面に8個、上面に8個、側面に8個のセンサを配置した。前面のセンサはメータの上下にそれぞれ4個ずつ配置し、直進時のハンドル位置において通常の運転姿勢をとった運転手の上半身が計測対象となるようにした。上面のセンサはサンバイザーの左右にそれぞれ4個ずつ、こちらも通常の運転姿勢をとった運転手の上半身が計測対象となる位置に配置した。また、側面のセンサーはA・Bピラー間のサイドルーフに8個を運転席に向けて設置した。センサの配置は各識別対象クラスにおいてセンサ値の違いがあれば良いため、訓練データと識別対象とするデータが同じセンサ配置で計測されていれば、この配置と異なるものであっても良い。実験では屋外の日光の当たる駐車場に車輻を停止させて、データ取得を行なった。室内実験と同様に実験参加者に口頭で9種類の運転姿勢をとるように依頼し、離散的に運転時の姿勢ごとにセンサ値を繰り返し取得した。実験参加者は普通自動車免許を取得している20代から70代の男女12名である。Table 1の9種類の姿勢に加え、Table 2に示すように追加の識別対象クラ

Fig. 5 Sensor value distribution on each driving posture

Fig. 6 A result of principal component analysis

スとして、子供を想定した 12 歳の平均身長サイズのマネキンがハンドルをもたず運転席に座った状態、肥満体を想定して腹部付近にクッションを入れた実験参加者がハンドルをもたず運転席に座った状態、運転席が不在の状態のときについても測定を行なった。

実験参加者は Fig. 4 の 9 種類の姿勢を順番にとり、1 つの姿勢について 50 回センサ値を取得する試行を計 10 試行繰り返した。実験参加者はおのおの普段運転するときのシートの位置や高さなどに調整した上で測定に参加した。Table 2 の 3 種類のクラスは、子供のマネキンを設置し計測、肥満体を模した実験参加者の計測、席に何も設置せずに計測の流れで、1 つの状態につき 50 回センサ値を取得する試行を繰り返し計 10 試行を行なった。機械学習には SVM を利用し、RBF カーネ

ル ($C = 100$, $\text{degree} = 3$, $\gamma = 0.1$) を用いて訓練を行なった。取得したデータは標準化によって特徴量のスケールを行ない、機械学習による識別率を検証した。まず、個人の姿勢をシステムに学習させた場合にシステムがその個人の姿勢を識別できるかを確認するために Table 1 の姿勢について個々の実験参加者のデータに対して 13 分割交差検証を行なった。実験参加者ごとの全姿勢の平均識別率を Table 3 に、姿勢ごとの全実験参加者の平均識別率を Fig. 10 に示す。

また、訓練とテストで異なる実験参加者群のデータを用いた場合でも姿勢を識別できるかを確認するために、実験参加者のデータを 1 つにまとめ、その全データの 75% を訓練用データ (訓練用データのうちの 10% は SVM の上記パラメータ決定と SVM の訓練両方に用いられた) に、残りの 25% をテス

Fig. 7 Exterior of the vehicle used in the experiment: during the experiment, the vehicle was parked at a car parking

Fig. 8 Sensor array layout

ト用データに用いて識別率を検証した。具体的には、実験参加者 A, B, C, D, E, F, G, H, I の全データを訓練データとして、実験参加者 J, K, L の全データをテストデータとして扱った。この識別結果を **Fig. 11** に示す。

さらに、Table 1 の姿勢と Table 2 のクラスが混ざっている状態の識別率を確認するため、実験参加者 A, B, C, D, E, F, G, H, I の全データと Table 2 のクラスの場合のデータの 75% を訓練データとして、実験参加者 J, K, L の全データと Table 2 のクラスの場合のデータの 25% をテストデータとして扱ったときの識別結果を **Fig. 12** に示す。

Table 3 に示すように、個人ごとの運転姿勢を学習させた場合、多くの実験参加者の運転姿勢は平均で 90% 以上の精度で識別できた。また、Fig. 10 に示すように、識別対象としたすべての姿勢において良好な識別精度を示した。一方、異なる実験参加者群の訓練データを用いた場合の識別率を検証したところ、Fig. 11 に示すように精度が低下する姿勢も見られたが、「右折姿勢」、「左折姿勢」、「前傾姿勢」、「ノーハンドル時の姿勢」においては 90% 前後の高い識別率を示した。「コン

(a) Front ToF Sensor Array

(b) Top ToF Sensor Array

(c) Side ToF Sensor Array

Fig. 9 Sensor arrays used in the experiment

Table 3 Accuracy of posture classification with user dependent training

Participant	Accuracy
A	0.870
B	0.942
C	0.814
D	0.907
E	0.944
F	0.929
G	0.914
H	0.922
I	0.932
J	0.922
K	0.914
L	0.944
平均	0.913

ソール使用時の姿勢」の識別率が全姿勢の中で最も低く、これはシステムが「前傾姿勢」や「ものを拾い上げる姿勢」のようなハンドルに身体を近づける動作と混同しているためと考えられる。「片手ハンドル時の姿勢（左手は頬に接触）」は 60% 前後の識別率となっており、一部を「スマートフォン使用時の姿勢」と誤認識している。これらの姿勢は実験参加者のとる関節角度のばらつきが大きく、センサ位置に応じて取得できる距離情報の分散も大きくなるためではないかと考えられる。これらの識別率の低い姿勢はどの場合も胴体の姿勢に大きな変化がないという共通点があり、違いは手を置いて

Fig. 10 Confusion matrix of posture classification with user dependent training

Fig. 11 Confusion matrix of posture classification on participant J, K and L with user independent training

Fig. 12 Confusion matrix of Tables 1 and 2 classification with user independent training

いる場所である。こうした姿勢の識別率向上のためには、手の位置の変化から姿勢の変化を識別できるようにセンサの配置を見直すことやセンサの数を増やすことが、識別率向上につながると考えられる。

Fig. 12 においては、Table 1 の 9 姿勢を 1 つのクラスにしたものと、「子供」、「肥満体」、「運転手が不在」を想定した

すべてのクラスについて高い精度で識別できた。これは実験条件では、測定を繰り返してもセンサ値に大きな変化がなく、ほかの実験参加者のデータと比べて距離情報の分布が大きく異なることから識別が容易だったと考えられる。実際に多様な子供や肥満体を実験参加者とした際には結果に変化が見られる可能性があるが、本実験の結果から提案手法によって大まかな運転手の有無・体型の違いなどを判別できると考えられる。

実験全体としては、異なる実験参加者群の訓練データを用いた場合、距離情報の分散が大きくなる「片手ハンドル時の姿勢（左手は頬に接触）」、「スマートフォン使用時の姿勢」、「コンソール使用時の姿勢」、「ものを拾い上げる姿勢」において識別率は低下しているが、「右折姿勢」、「左折姿勢」、「前傾姿勢」、「ノーハンドル時の姿勢」のような基本的な運転姿勢に対しては、高い識別精度が確認できた。また、同様の手法で「子供」、「肥満体」、「運転手が不在」を想定したデータを取得し、識別対象とする運転姿勢と誤認識することなく識別できることを確認した。複数の測距センサの距離情報の分布から運転手の姿勢や体型の異なる搭乗者を想定したクラスの識別が可能であった。

5. 結 論

本稿では、複数の測距センサを車内のコックピットに配置することで自動車の搭乗者の姿勢を識別する手法を提案した。従来の運転手の姿勢や状態識別技術としてカメラの画像を用いて推定する手法や、奥行きセンサを用いる手法、慣性センサを用いる手法が挙げられるが、計算負荷やユーザへの装着負荷が大きく、カメラを使用する手法ではプライバシーへの配慮が小さいという課題があった。本提案手法では、それらの課題を克服しつつ、搭乗者の姿勢に応じて複数の測距センサで取得できる距離情報の分布から識別を行なう手法を提案し、取得したデータを機械学習することで、実験参加者個々の運転姿勢の識別が高い精度で可能であることを示した。ほかの実験参加者の訓練データを用いた識別での精度の悪い運転姿勢に対しては、訓練データを取得する際の試行回数を増加させることやセンサの配置や数を変更することで、識別率向上が期待できる。

測距センサを複数用いることで、基本的な運転姿勢を高精度に識別できたことから、運転手の姿勢を把握する上で提案手法は有用であると考えられる。今後の展望としては、時系列データを取得し、距離情報の推移からジェスチャなどを識別できるかについて検討することも提案手法の可能性を広げる上で、有益であると考えられる。

参 考 文 献

- 1) D.A. Johnson and M.M. Trivedi: Driving style recognition using a smartphone as a sensor platform, *2011 14th International IEEE Conference on Intelligent Transportation Systems (ITSC)*, 1609/1615 (2011)
- 2) T. Gandhi and M.M. Trivedi: Pedestrian protection sys-

tems: Issues, survey, and challenges, *IEEE Transactions on Intelligent Transportation Systems*, **8**-3, 413/430 (2007)

- 3) M. Hitosugi, S. Gomei, T. Okubo and S. Tokudome: Sudden illness while driving a vehicle—a retrospective analysis of commercial drivers in Japan, *Scandinavian Journal of Work, Environment & Health*, **38**-1, 84/87 (2011)
- 4) M. Hitosugi: Useful Knowledge about the disease and medicine for drivers, *The Journal of Science of Labour*, **87**-6, 240/247 (2011)
- 5) S. Kawachi, M. Hitosugi, T. Maki and T. Sakurai: Vehicle driving posture at drivers' unconsciousness and accident prevention, *Japanese Journal of Occupational Medicine and Traumatology*, **61**-2, 144/147 (2013)
- 6) H.L. Lemley, J. Chodosh, T.C. Wolf, C.P. Bogie and T.C. Hawkins: Partial dislocation of laser in situ keratomileusis flap by air bag injury, *Journal of Refractive Surgery*, **16**-3, 373/374 (2000)
- 7) J.L. Nichols, D. Glassbrenner and R.P. Compton: The impact of a nationwide effort to reduce airbag-related deaths among children: An examination of fatality trends among younger and older age groups, *Journal of Safety Research*, **36**-4, 309/320 (2005)
- 8) SAE International: Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles, J3016 (2018)
- 9) S.-E. Wei, V. Ramakrishna, T. Kanade and Y. Sheikh: Convolutional pose machines, *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 4724/4732 (2016)
- 10) C. Yan, B. Zhang and F. Coenen: Driving posture recognition by convolutional neural networks, *2015 11th International Conference on Natural Computation (ICNC)*, 680/685 (2015)
- 11) C.H. Zhao, B.L. Zhang, J. He and J. Lian: Recognition of driving postures by contourlet transform and random forests, *IET Intelligent Transport Systems*, **6**-2, 161/168 (2011)
- 12) Y. Abouelnaga, H. Eraqi and M. Moustafa: Real-time distracted driver posture classification, *2018 NIPS Workshop on Machine Learning for Intelligent Transportation Systems* (2018)
- 13) A. Haque, B. Peng, Z. Luo, A. Alahi, S. Yeung and L. Fei-Fei: Towards viewpoint invariant 3D human pose estimation, *Computer Vision – ECCV 2016*, 160/177 (2016)
- 14) M. Martin, S. Stuehmer, M. Voit and R. Stiefelhagen: Real time driver body pose estimation for novel assistance systems, *2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC)*, 1/7 (2017)
- 15) A.M. Sabatini: Quaternion-based extended Kalman filter for determining orientation by inertial and magnetic sensing, *IEEE Transactions on Biomedical Engineering*, **53**-7, 1346/1356 (2006)
- 16) C.M. Yang, C.C. Wu, C.M. Chou and T.L. Yang: Vehicle driver's ECG and sitting posture monitoring system, *2009 9th International Conference on Information Technology and Applications in Biomedicine*, 1/4 (2009)
- 17) N. Miyata, T. Honoki, Y. Maeda, Y. Endo, M. Tada and Y. Sugiura: Wrap & sense: Grasp capture by a band sensor, *The 29th Annual Symposium on User Interface Software and Technology*, 87/89 (2016)

[著者紹介]

山賀 瑛斗

2017年芝浦工業大学デザイン工学部デザイン工学科卒業。同年、慶應義塾大学大学院理工学研究科開放環境科学専攻修士課程入学。測距センサと機械学習を用いたヒトの姿勢計測技術に関する研究に従事。

浅野 直生

2017年慶應義塾大学理工学部情報工学科卒業。同年、同大学院理工学研究科開放環境科学専攻修士課程入学。光センシングと機械学習を用いた表情の計測技術に関する研究に従事。

杉浦 裕太

2013年日本学術振興会特別研究員(PD)。2014年慶應義塾大学大学院メディアデザイン研究科特任助教。2015年、(独)産業技術総合研究所人間情報研究部門デジタルヒューマン研究グループ産総研特別研究員。2018年より慶應義塾大学理工学部情報工学科専任講師。情報処理学会山下記念研究賞受賞。ヒューマンコンピュータインタラクションに関する研究に従事。

杉本 麻樹(正会員)

2006年電気通信大学大学院電気通信学研究科博士後期課程機械制御工学専攻修了。博士(工学)。日本電信電話(株)NTTコミュニケーション科学基礎研究所客員研究員、日本学術振興会特別研究員(DC1/PD)、電気通信大学電気通信学部知能機械工学科特任助教、慶應義塾大学大学院メディアデザイン研究科特別研究講師などを経て、現在、慶應義塾大学理工学部情報工学科准教授。複合現実環境における光センシングに関する研究に従事。