

視線・顔向き情報に基づいた電動車いす操作インタフェースの開発 Development of an Electric Wheelchair Operation Interface Based on Eye and Face Information

比嘉 聖[†] 山田 孝治[†] 神里 志穂子[‡]
Sho Higa Koji Yamada Shihoko Kamisato

1. はじめに

近年、肢体不自由者の多様性に応じて様々なユーザインタフェースの開発が行われている。脳波を用いた電動車いす操作技術の開発や音声コマンドで操作可能な電動車いすの研究などが行われており、手法の一つとしてインタフェースに使用者の視線を用いる試みがなされている。眼球運動は麻痺の影響を受けにくいいため、搭乗者が注視する方向に電動車いすを走行させるというように、ハンズフリーで直感的な操作が可能なインタフェースとして期待されている。ヒトは意識的に視線を動かすこともできるが、進む方向を見るだけでなく、周囲確認や特定の対象物への注目、および視界外からの障害物や第三者の進入などの外乱の発生に備えて、顔や視線を無意識的に動かしている。このような探索のための無意識的な眼球運動も入力操作として扱われることを *Midas Touch Problem* と呼び、注視の識別が重要となる[1][2]。しかしこれら2つの眼球運動は特徴がほぼ同じであるため識別が難しいという課題がある。

視線動作の識別に関して、注視を用いた入力方式とジェスチャを用いた入力方式に関する研究が行われている。注視入力方式は入力対象・方向を一定時間、意識的に注視することで選択を行う[3][4]。この手法は入力に必要な注視時間を長く設定することで視線動作の識別を行っており、ALS(筋萎縮性側索硬化症)患者などの重度肢体不自由者が利用する文字入力システムに採用されるなど一般的な入力方式となっている。シンプルな操作が可能な反面、入力に要する時間が長くなるために入力速度や操作性の低下が課題である。ジェスチャ入力方式は視線の移動パターンを入力とする方式であり、サックードと呼ばれる極めて高速で随意的な眼球運動を組み合わせることでジェスチャ入力を行う[5][6]。特にジェスチャ入力方式は視線検出に加えて、判別しやすいジェスチャの設定や出力数の検討やジェスチャの認識手法の精度向上が重要となる。

本研究はこれまでに、車両等の走行中は基本的に進みたい方向に視線を向けるという考えから、注視入力方式を採用した電動車いすの開発を行ってきた。注視入力方式では走行中の周囲確認が容易だが、視線動作の識別に一定時間の注視を要するため、即座に右左折したいときに走行に反映されるまでラグが発生し、操作性の低下に繋がるのが確認されている[7]。注視入力のみではインタフェースとして低性能であるため他要素も組み合わせた識別手法の検討を行う。

ここで、ヒトの意図を視線動作から推定する手法が考案されており、「迷い」状態の推定や調理動作の識別に成功

している[8][9]。これらの研究は被験者にタスクを与えたときに生じる規則的な視線動作に被験者の意図が含まれているとし、その注視の遷移パターンをサポートベクターマシン (Support Vector Machine : SVM) や Random Forest などの機械学習モデルで学習することで被験者の状態推定やタスクの識別を行っている。このことから、注視入力のみによる明示的な操作ではなく、注視の有無や視線の位置・速度、それらの時間的な変化といった自然な振る舞いから搭乗者の意図推定を行うことで操作性の向上を図ることができると考える。また、ヒトは対象を注視するときや周囲確認時は視線だけでなく、顔も連動していることがある。例として、視界外や視界の端にある物体を見るときは顔を動かして詳細に見ようとするなど、視線と顔の動きは密接に関係している。

そこで本研究では、搭乗者の自然な視線・顔向き動作で操作可能な電動車いすの開発を目的として、視線・顔向き情報に基づいた意図推定手法を考案する。本稿では、はじめに関連研究と開発する電動車いす操作システムについて述べる。次に、意図推定モデルについて説明し、評価を行う。

2. 関連研究

本章では既存の注視入力方式のアルゴリズムと意図推定モデルについて述べる。

2.1 注視量ヒストグラムによる注視判定

本節では、注視量ヒストグラムを用いた注視判定手法について述べる。注視量ヒストグラムは足立ら[4]が考案した注視の度合い(注視量)をヒストグラムとして表現したモデルであり、ヒトが任意方向に視線を意識的に向ける場合、その方向に注意が発生しているという考えに基づいている。まず初めに、ヒトの視覚において高精細な範囲は中心窩と呼ばれる網膜中央部の約2度の範囲であり、中心に近いほど視力が高くなり、物体を鮮明に見ることができる。すなわち視野全体の内、中心に近づくほど注視の度合いが高いと考えられる。ここで、視野全体の注視量は注視している方向を中心にピークを持つ分布とし、同じ方向を見続けることで注視量が高まるように時刻毎に2次元の正規分布 g_i をヒストグラム w_i に与える。以下に注視量ヒストグラムの数式とパラメータを示す。

このとき、同じ方向を注視し続けた場合はその方向に対するヒストグラム度数が $A/(1-\alpha)$ に収束する。収束値を100%として、度数が90%以上となったときは注視していると判定される。

[†] 琉球大学 University of the Ryukyus

[‡] 沖縄工業高等専門学校 National Institute of Technology, Okinawa College

$$w_i(t) = \alpha \cdot w_i(t - \Delta t) + g_i(t) \quad (1)$$

$$g_i(t) = A \cdot \exp \{ -(\phi_m^2 + \phi_n^2) / 2\sigma^2 \} \quad (2)$$

$w_i(t)$: 注視点*i*での時刻*t*のヒストグラム度数

α : ヒストグラム度数の減衰率

ϕ_m : 注視点*i*と視線方向の角度差(水平方向)

ϕ_n : 注視点*i*と視線方向の角度差(垂直方向)

σ : 正規分布の標準偏差

A : 定数

2.2 視線動作の時系列パターンに基づく意図推定手法

本節では井上ら[9]による視線動作の時系列パターンに基づいた意図推定手法について述べる。井上らは調理の基本動作を調理者の視線パターンに基づいて識別する手法を提案した。調理動作時の視線計測によって得られた視線遷移と停留、瞬きを含む時系列データから「Cut」、「Mix」、「Crush」、「Peel」、「Wait」という5種類のラベルを持つ教師データを作成し、Random Forestによって特徴抽出を行っている。視線計測データはx座標系列、y座標系列の時系列データからなっており、データの前処理としてメディアンフィルタによるノイズ除去を行っている。次に各フレーム(*b*)について、数フレーム前からの時系列データをHaarウェーブレットによる連続ウェーブレット変換と閾値による判定で視線遷移ベクトル $C(b) = ((C_x(b), C_y(b)))$ を求める。量子化された各フレームの視線遷移ベクトル $C(b)$ は、その向きと長さに応じて記号が付与される。記号化によって得られた記号列には視線遷移パターンが含まれているため、N-gramを用いて記号列から各パターンの抽出を行い、Random Forestへ入力するための特徴ベクトルとしている。

Random Forestによる識別結果は7割以上の標本を正しく識別しており、平均識別率は66.2%となっている。

3. 提案手法

2章で述べたように、井上らは視線遷移のパターン抽出によって調理動作の識別に成功している。しかし、視線動作のみで、頭部の動きは考慮されていない。視線と顔の動きは密接に関係しているため、顔動作も考慮することで精度が向上すると考える。

そこで本研究では、注視の有無や視線・顔の位置・速度、それらの時間的変化といった自然な振る舞いから搭乗者の意図推定を図る。

3.1 電動車いす操作システムの概要

本節では開発する電動車いす操作システムについて述べる。図1にシステムの構成を示す。操作システムは、タブレット端末と電動車いす、電動車いす制御用のコンピュータから構成される。電動車いすはWHILL社製の研究開発モデルWHILL Model CRを使用する。表1にWHILL Model CRの仕様を示す。タブレット端末はApple社製のiPad Proを使用し、ARKit Face Tracking機能を用いることで視線・顔動作計測を行う。ARKit Face Trackingは搭乗者の正面に設置したタブレット端末のカメラから搭乗者の顔を撮影・認識し、カメラに対する視線・顔の相対角度および瞬目や口角の上がり具合などといった表情に関するパラメータ値

の取得が可能である。本研究では視線・顔の相対角度を電動車いすの走行制御に使用する。計測範囲は搭乗者の頭部正面方向を中心として、水平方向に±90°、垂直方向に±60°とした。分解能は0.1°、サンプリング周波数は5Hzである。視線・顔情報の取得から走行までのプロセスを以下に示す。

1. タブレット端末のカメラ画像からフレーム(*t*)毎に搭乗者のカメラに対する視線・顔の相対角度[deg]を取得する。頭部正面方向を中心に、垂直角を $v_{angle}(t)$ 、水平角を $h_{angle}(t)$ と表す。
2. 電動車いすWHILLは独自の計算式でジョイスティックのx軸の値を並進速度、y軸の値を角速度として速度指令に変換し、モータに与えている。そのため視線・顔の相対角度をジョイスティック入力と同様に扱うことで速度指令に変換できる。すなわち、垂直角 $v_{angle}(t)$ をジョイスティックのY軸、水平角 $h_{angle}(t)$ をジョイスティックのX軸とすることで、視線・顔の動きに応じて速度指令を与えることができる。ここで、肢体不自由者は筋肉の麻痺・硬直により後方確認が容易ではないため、提案する電動車いすは前進・右左折のみの走行に制限し安全性を担保する。また、垂直角に応じて並進速度を変化させると不安定な走行となる。そこで、垂直角 $v_{angle}(t)$ をスイッチとして用いる。具体的には、(1)式に示すように閾値 th によって走行のON・OFFを切り替える。次に水平角 $h_{angle}(t)$ は(2)式により係数を掛けて入力に用いる。このように搭乗者は視線もしくは顔を移動したい方向に向けると走行することができる。

$$v_d(t) = \begin{cases} ON & (v_{angle}(t) > th) \\ OFF & (v_{angle}(t) < th) \end{cases} \quad (3)$$

$$h_d(t) = \alpha \cdot h_{angle}(t) \quad (4)$$

3. 与えられた速度指令に従って電動車いす走行を行う。電動車いすから制御PCに対して現在速度・加速度センサー値を返す。

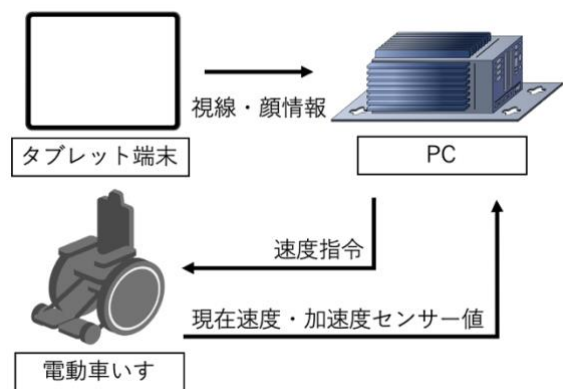


図1 操作システムの構成

表1 WHILL Model CR の仕様

重量	52kg
最高速度	6km/h
サイズ	550(W)×985(L)×740-940(H)mm
通信方式	RS232C
搭載センサー	加速度センサー モーターエンコーダ
供給電源	24* V(1A×3ピン), GND

3.2 視線・顔計測データの前処理

本節では視線・顔計測データの前処理について述べる。

視線・顔計測データはそれぞれの x 座標系列, y 座標系列の時系列データからなっている。一般に, 視線計測は 0.5° 程度の計測誤差を含むとされており, またヒトの眼球運動には固視微動と呼ばれる対象への注視を行うときに発生する微小な振動がある。これらのノイズを低減するためにデータの前処理として, 各系列に対して移動平均点処理による視線・顔計測データの平滑化を行う。本稿では 5 点移動平均により平滑化を行った。

3.3 特徴ベクトルの作成

本節では使用する特徴ベクトルおよび, データセットについて述べる。

2 章でも述べたように, 井上らは視線遷移パターンに基づいた調理動作識別手法が考案しており, 視線遷移パターンは現在の状態に過去の状態を加えた時系列データであるため, 動作識別や心理状態の推定に有効的だと考える。また視線と顔の動きは密接に関係しているため, 顔動作も考慮することで精度が向上すると考える。そこで本稿では電動車いす走行時の視線・顔情報と移動方向をセットにした時系列データを作成し, 再帰型ニューラルネットワークを学習させることで意図推定モデルの構築を行う。

視線・顔計測データは前節で述べたとおり, それぞれの x 座標系列, y 座標系からなっている。フレーム毎にこれらの位置ベクトルを一階微分することで移動速度を求め, 更に移動速度の標準偏差を算出する。ここで, ヒトの視線・顔の自然な振る舞いから意図推定を行うには, 位置・速度といった動作に関する特徴量だけでなく, 「注視の有無」という心理状態が表出しやすい特徴量が重要となる。そこで 2.1 節で述べた注視量ヒストグラムを用いて注視判定を行い, 特徴量を算出する。本稿ではヒストグラム度数の減衰率 α を 0.95 とし, 判定に必要な注視時間は 700[ms]程度とした。一般にサッケードが終了してから次のサッケードが始まるまでの視線停留時間は 150[ms]~500[ms]程度とされており, 今回設定した 700[ms]程度の注視時間は妥当であると考えられる。

これにより, スムースパシュートと呼ばれるゆっくり移動する対象へ追従する低速な眼球運動を行っている場合は連続的に注視を行っているとして判定され, 周囲確認や進行方向を見るためにサッケードを繰り返している場合は離散的に注視を行っているとして判定されるなど, 識別に寄与すると考える。以上のように, 意図推定モデルに使用する特徴ベ

クトルは視線・顔それぞれの位置, 速度, 標準偏差, 注意の有無とする。

3.4 1d-CNN+LSTM による識別機の構築

本研究では, サンプリング周波数 5Hz, 一定時間毎の特徴ベクトルを識別機へと入力し, ジョイスティックの傾き量の制御を行う。提案する識別器について, 特徴抽出部と識別部に分けて述べる。

3.4.1 1d-CNN を用いた特徴抽出部

1次元信号である視線・顔計測データの特徴ベクトルから特徴抽出をおこなうために, 1d-CNN を用いた特徴抽出器を構築する。1d-CNN は 1次元の入力信号に対して, 1次元の畳み込みフィルタを時間方向にスライドして畳み込むことで特徴的な信号を抽出する畳み込みフィルタを学習により得ることができる。本研究では, 2種類のフィルタを用いて特徴抽出を行う。1つ目は低周波成分の抽出を行うために, フィルタサイズを可変とする。具体的には使用するデータセットの説明変数には区間毎(T フレーム)の特徴ベクトルを使用する。この区間は 0.2[s] ($T = 1$), 1[s] ($T = 3$), 1[s] ($T = 6$), 2[s] ($T = 11$), 3[s] ($T = 16$)の4パターンを用意し, 1つ目のフィルタサイズに適用する。2つ目は信号の振幅抽出を行うために, フィルタサイズを最も小さい 1 を固定値とする。

3.4.2 LSTM を用いた識別部

1d-CNN で抽出した特徴量を, RNN(Recurrent Neural Network)の1つである LSTM(Long short-term memory)を用いた識別部へ入力する。RNN は再帰型ニューラルネットワークと呼ばれる時系列データの処理を得意とするモデルであり, 中間層がループする構造を持つことで過去の状態を考慮した処理が可能である。LSTM は RNN モデルの勾配が消失しやすいという問題点を改善し, 長期間に渡る安定的な学習が可能なモデルである。

こちらの特徴抽出部に合わせて 2つの識別器を用意し, それぞれの出力結果を結合した後, 全結合層にて多クラス識別を行う。

学習の損失関数は交差エントロピー, 最適化法は Adam, 学習率は 0.001 とした。エポック数は 150, バッチサイズは 10, ドロップアウト率は 0.5 とした。

4. 評価実験

4.1 データセット

次に, データセットの作成について述べる。データセットは意図推定モデルの学習に使用されるデータのことであり, 予測する変数である「目的変数」と目的変数を説明する「説明変数」からなる。目的変数はジョイスティックの傾き量に応じたラベルを使用する。まず, ジョイスティックの x 軸, y 軸の値から方位角 θ [deg] ($0 \leq \theta \leq 180$)を求め, 次式に従って整数値のラベル L が付与される。それぞれのラベルは「0:前進」「1:右折」「-1:左折」を表す。

$$L = \begin{cases} -1 & (0 \leq \theta < 80) \\ 0 & (80 \leq \theta \leq 100) \\ 1 & (100 < \theta \leq 180) \end{cases} \quad (5)$$

表 2 1d-CNN フィルタサイズの可変による正解率の比較

	0.1sec(1)		0.5sec(3)		1sec(6)		2sec(11)		3sec(16)	
	Accuracy	F-measure	Accuracy	F-measure	Accuracy	F-measure	Accuracy	F-measure	Accuracy	F-measure
A	91.92	89.59	93.83	92.24	94	92.49	93.79	92.39	93.59	92.24
B	77.8	74.8	76.58	73.36	82.46	80.74	84.26	83.1	82.28	80.93
C	82.18	78.28	86.61	83.63	90.06	88.5	88.68	86.37	88.43	86.65
Average	83.97	80.89	85.67	83.08	88.84	87.24	88.91	87.29	88.1	86.61

表 3 視線動作と顔動作の組み合わせによる有効性の検討

	Eye+Face		Eye		Face	
	Accuracy	F-measure	Accuracy	F-measure	Accuracy	F-measure
A	93.79	92.39	92.17	90.3	88.51	85.45
B	84.26	83.1	81.54	80.47	81.75	78.3
C	88.68	86.37	88.35	85.82	80.47	74.85
Average	88.91	87.29	87.35	85.53	83.58	79.53

次に特徴ベクトルの時間的変化を考慮し、説明変数には区間毎(T フレーム)の特徴ベクトルを使用する。この区間は 0.2[s] ($T = 1$), 1[s] ($T = 3$), 1[s] ($T = 6$), 2[s] ($T = 11$), 3[s] ($T = 16$)の 4 区間とする。また、これまでの述べた視線・顔の位置、速度、標準偏差、注意の有無といった特徴ベクトルは、単位やスケールがそれぞれ異なる。特徴ベクトル間で値の大きさにバラツキが生じると推定精度に多大な影響を及ぼすため、区間毎に正規化を行う。

これらの学習データセットを作成するため、右左折と前進を行うコースを電動車いすで 10 分間走行(標本数 3540)し、視線・顔計測データを収集した。同様に、評価用のテストデータ作成のため、学習用のデータセットとは異なるコースを 2 分間走行(標本数 506)し、視線・顔計測データを収集した。

4.2 1d-CNN のフィルタサイズの検討

3.1 節で述べたように、本稿では 2 種類の畳み込みフィルタを用いて特徴抽出を行っており、1 つ目のフィルタサイズを 3.3 節で述べた区間 T とし、2 つ目のフィルタサイズは固定値としている。

そこで本実験では 1 次元信号の特徴抽出を行う 1d-CNN のフィルタサイズの違いによる一致率を比較し、最も良い一致率で判定可能な特徴抽出部のモデルを検討する。

被験者は 20 代の男性 3 名とし、被験者毎に学習データによる学習と、テストデータによる評価を行った。評価指標は Accuracy, F-measure の 2 つとする。Accuracy は識別機の出力結果と正解ラベルとの一致率である。F-measure は識別機の総合的な評価に使用される評価指標で、適合率と再現率の調和平均で求める。結果について表 2 に示す。

実験結果から、いずれのフィルタサイズでも 80% 以上の精度で判定可能であり、最も良い一致率はフィルタサイズ $T = 11$ の畳み込みフィルタで Accuracy が 88.91%, F-measure が 87.29% だった。 $T = 6$ と $T = 11$ のフィルタサイズ間では大きな違いは見られず、この 1[s]~2[s] の区間に特徴的な視線・顔動作パターンが含まれていると考えられる。また、 $T = 1$ のフィルタサイズで Accuracy が 83.97%, F-measure が 80.89% と最も低い一致率だったことから、特徴ベクトルの時間的変化を考慮した時系列データセットの作成方法は識別に有効的であると示唆される。

4.3 視線・顔動作の組み合わせによる有効性の検討

1d-CNN+LSTM による意図推定に視線動作と顔動作の組み合わせがどの程度有効なのか検証を行う。4.2 節で決定したフィルタサイズを用いて被験者毎に学習データによる学習と、テストデータによる評価を行った。それぞれ「視線動作+顔動作」「視線動作のみ」「顔動作のみ」の 3 パタ

ーンを用意した。4.2 節と同様に被験者は 20 代の男性 3 名とし、評価指標は Accuracy, F-measure の 2 つとする。結果について表 3 に示す。

実験結果から、視線動作と顔動作を組み合わせたデータセットの方が、Accuracy が 88.91%, F-measure が 87.29% と最も良い一致率だった。また顔動作のみのデータセットでは Accuracy が 85.38%, F-measure が 79.53% と視線動作と顔動作を組み合わせた場合とで顕著に差が出ている。

これは学習データ、テストデータにおいて顔動作の方が視線よりも低速で、主に視線を動かすことで周囲確認や進行方向を見ており、視野外の物体や視野の端にある物体を見るときに顔を動かして詳細に見ようとするなど、顔の動きは視線の補助的な役割であることが原因であると考えられる。また、視線動作のみのデータセットでは Accuracy が 87.35%, F-measure が 85.53% と視線動作と顔動作を組み合わせた場合とで 1.7% 程の差が出た。このことから、視線動作だけでなく、顔動作も組み合わせることで意図推定のための表現力が向上し、識別に寄与することが示唆された。

4.4 意図推定モデルの有効性

本節では提案手法である 1d-CNN+LSTM のモデル構成の有効性を検討するため、LSTM との比較を行う。1d-CNN+LSTM は畳み込みフィルタ層によって特徴ベクトルから特徴量を抽出し LSTM 層への入力に用いるが、比較手法の LSTM では特徴ベクトルをそのまま特徴量として入力に用いる。4.2 節で決定したフィルタサイズを用いて被験者毎に学習データによる学習と、テストデータによる評価を行った。4.2 節と同様に被験者は 20 代の男性 3 名とし、評価指標は Accuracy, F-measure の 2 つとする。結果について表 4 に示す。

実験結果から、提案手法である 1d-CNN+LSTM の Accuracy が 88.91%, F-measure が 87.29% となり比較対象手法の LSTM とは 1.5% 程度の差が出た。それほど大きな差は

見られないが、畳み込みフィルタによる特徴抽出が一致率に寄与していることが伺える。

表4 顔情報と視線情報の組み合わせによる有効性の検討

	1d-CNN+LSTM		LSTM	
	Accuracy	F-measure	Accuracy	F-measure
A	93.79	92.39	93.23	91.89
B	84.26	83.1	80.68	79.06
C	88.68	86.37	88.48	86.29
Average	88.91	87.29	87.46	85.75

5. おわりに

本研究では、搭乗者の自然な視線・顔向き動作で操作可能な電動車いすの開発を目的としている。本稿では、意図推定モデルの構築として、数フレーム分の区間毎の視線・顔向き情報を組み合わせ時系列データセットの作成、および1d-CNN+LSTMを用いた識別器を構成した。実験により得られた結果から、1[s]~2[s]の区間に特徴的な視線・顔動作パターンが含まれていると考えられ、特徴ベクトルの時間的変化を考慮した時系列データセットの作成方法は識別に有効であることが確認された。また、視線動作の時系列データだけでなく、顔動作も組み合わせることで意図推定のための表現力が向上し、識別に寄与することが示唆された。最後に、LSTM層に畳み込みフィルタ層を追加することで精度が向上し、畳み込みフィルタによる特徴抽出が一致率に寄与していることが確認された。

しかし、提案したモデルは学習データに依存し、学習データのラベルも右左折と前進の3つのみでMidas Touch Problemを回避するには不十分である。

今後は、「停止」「物体への注視」といったラベルと付随する視線・顔動作の計測データの収集、および構築した意図推定モデルを電動車いすの操作インタフェースとして使用した場合の走行評価を行う。

参考文献

- [1] Boris Velichkovsky, Andreas Sprenger, Pieter Unema, "Towards gaze-mediated interaction: Collecting solutions of the "Midas touch problem"", Human-Computer Interaction: INTERACT'97, pp.509-516, 1997.
- [2] Hana Vrzakova, Roman Bednarik, "That's not norma(n/l)! A detailed analysis of midas touch in gaze-based problem-solving", ProceedingCHI EA '13 CHI '13 Extended Abstracts on Human Factors in Computing Systems, pp.85-90, 2013
- [3] 松本吉央, 伊野智行, 小笠原司: 顔と視線情報による電動車いすの走行支援システム, 電気学会システム・制御研究 SC-10-30, pp.59-64, 2001.
- [4] 足立佳久, 恒成裕行, 松本吉央, 小笠原司: "ユーザの注意推定に基づく搭乗型移動ロボットの走行支援システム" ヒューマンインタフェース学会論文誌, Vol.6, No.3, pp.265-274, 2001.
- [5] Diogo de Graça Pedrosa, Maria da Graça Campos Pimentel, Amy Wright, Khai N. Truong, "Filtering design challenges and user performance of dwell-free eye typing", ACM Transactions on Accessible Computing, Vol.6, no.1, 1-37, 2015.
- [6] Andrew Kurauchi, Wenxin Feng, Ajjan Joshi, Carlos Morimoto, Margrit Betke, "EyeSwipe: Dwell-free TextEntry Using Gaze Paths", Proceedings of the 34th SIGCHI Conference on Human Factors in Computing Systems, CHI '16, pp. 1952-1956, 2016.
- [7] 比嘉聖, 山田孝治, 神里志穂子: "視線・顔情報を用いた電動車いす操作における特徴量抽出", 第187回ヒューマンコンピュータインタラクション研究発表会, 研究報告ヒューマンコンピュータインタラクション (HCI), 2020-HCI-187, No.25, p.1-4, 2020.

- [8] 高木啓伸: "視線の移動パターンに基づくユーザの迷いの検出-効果的な作業支援を目指して", 情報処理学会論文誌, Vol.41, No.5, pp.1317-1327, 2000.
- [9] 井上裕哉, 平山高嗣, 道満恵介ほか: "視線遷移と瞬きの時系列パターンに基づく調理動作識別手法", 電子情報通信学会論文誌 A, Vol. J100-A, No.1, pp.12-23, 2017.