

脳波からの指示による 電動車いす制御システムの実装と評価

中沢 実^{1,a)} 鷹箸 孝典¹ 阿部 拓真¹

概要：

近年、人の脳活動を読み取る研究の発展は目覚ましい。脳活動を読み取るには脳波 (EEG) や機能的磁気共鳴画像法 (fMRI) など、いくつかの方法が存在する。非侵襲的な EEG においては、リアルタイムで利用者の思考や感情、表情の検出や脳波の生データへ容易にアクセスできる製品が世の中に出ている。また、これらの脳波データを用いた工業用製品も徐々にではあるが、登場してきている。

そこで、本論文では、既存の基礎研究に基づいて、福祉分野における人の脳活動の活用を現実世界で適用させることを目的とし、利用者が初めて訪れる施設であっても脳波から利用者の意図を読み取り、容易に目的地まで辿り着くシステムの実現を目的とする。

キーワード： 脳波, 車椅子制御, 深層学習, 自己位置推定技術

Implementation and it's Evaluation of Autonomous Moving WheelChair System using EEG

Abstract: Recently, It is remarkable to develop of the research to read human brain activity. There are some method for reading the brain activity, for examples, electroencephalogram(EEG) and functional magnetic resonance imaging(fMRI). In the noninvasive EEG, the product which can access the thought and the feelings of the user, the detection of the expression using electroencephalographic raw data easily in a real time appears in the commerce. In addition, the industrial product using electroencephalographic data gradually comes up, too.

In this article, it is intended that utilization of the brain activity of the person in the field of welfare is applied in actual world based on existing fundamental researches, and the intention of the user is read from electroencephalogram even if it is the facility which a user visits for the first time, and I am aimed for system implementation to arrive at easily to the destination.

Keywords: EEG, Wheel Chair control, Deep Learning, SLAM

1. はじめに

近年、ヒトの脳活動を読み取りコンピュータとのインタフェースとして利用する (BCI: Brain Computer Interface) 研究が盛んに行われている。脳活動を読み取る方法には侵襲型と非侵襲型が存在する。侵襲型は、脳に直接電極を埋め込むため、メリットには明瞭で豊富な脳活動情報を取得できるという点があり、デメリットには手術を行う必要があるということや感染症を引き起こす可能性があるという

点がある。

非侵襲型は、頭皮にセンサを装着するだけであることから誰でもすぐに使用することができる。しかし、侵襲型に比べてノイズが多くなり性能が劣る。非侵襲型は侵襲型よりも安全であることから、非侵襲型はヒトに対する実験が盛んに行われている [1], [2]。

以上を踏まえた上で、本研究では、誰でも容易に使用することができる非侵襲型である脳波計 (EEG: Electroencephalography) を採用し、遠隔操作ロボットへのインタフェースとする。

EEG においては、リアルタイムで利用者の思考や感情、

¹ 金沢工業大学
7-4, Ohgigaoka, Ishikawa, 921-8501, Japan
^{a)} nakazawa@infor.kanazawa-it.ac.jp

表現の検出や脳波データへ容易にアクセスできる製品が世の中に出ている [3]. また, fMRI においては, ある画像を見た場合とその画像を想像した場合の差におおよそ違いはないといった研究結果が出ている [4].

これらの基礎研究に基づいて, 福祉分野におけるヒトの脳活動の活用を現実世界で適用させ, 日常生活で車いすを利用する人へ安心できる生活を提供するための一つとなることが本研究での最終目的である. 従来事例では, 非侵襲型 EEG を入力インタフェースとして用いた車いすへの適用例として従来の応用研究では, 前・右・左の三方向を指定して車いすの制御を行う方法が取られている [5].

しかし, 三方向の指定では常にどの方向に移動したいかを思考しているため, 利用者への負担が大きい. また, 利用者が危ないと判断し, 緊急停止をしたい場合に利用者が思考してから車いすへ命令が届き動作するまでに遅延が生じてしまう. そこで, 初めて訪れる施設であっても脳波から利用者の意図を読み取り, 車いすへコマンドを送ることで容易に目的地まで辿り着くシステムを実現を目的とする.

2. システム概要

構成するシステムを説明し, 全体像を図 1 に示す. 本システムでは, 脳波測定ヘッドセット (Emotiv EEG), PC, 車いす (JW アクティブ), 各センサ類の Laser Range Finder (LRF) や Bluetooth Low Energy (BLE) を用いる. また, LRF は車いすロボットに搭載し, 自己位置推定と障害物回避に使用する. BLE は Raspberry Pi に搭載し, ビーコン端末として使用する.

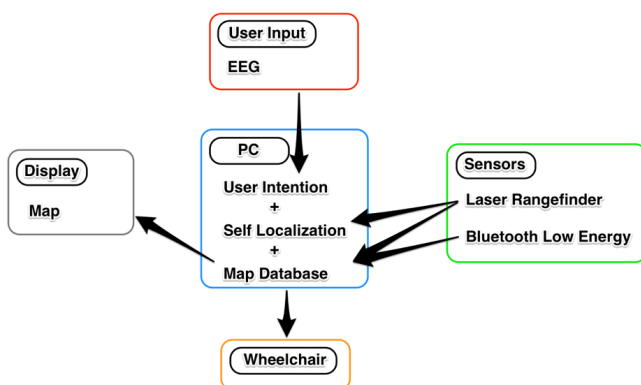


図 1 全体のシステム構成

2.1 構成要素の役割

本システムを構成する各要素の役割を説明する. 脳波測定ヘッドセットは利用者から得た脳波データを PC へ転送する. PC は, 脳波データを受け取り, 利用者の意図するコマンドへ変換し, 車いすへ命令を送ることや車いすの現在位置を把握し, ユーザに地図データを表示する. LRF は,

地図データの生成および車いすの自己位置の認識, 利用者の安全を確保するために用いる. BLE を搭載したビーコン端末は施設内の地図データを利用者に示す際に各フロアにおける位置情報を提供する.

2.2 システムの流れ

本システムの流れを図 2 に示す. 本システムは大きく分けて, BLE システム, EEG システム, 自律システムの 3 つから構成される. BLE システムでは, 現在利用者がいるフロアの BLE をスキャンし, そのフロアの地図データを取得するところまでの役割を担当する.

地図データは利用者に表示するものと自律システムで使用するものがある. EEG システムでは EEG からユーザの意図を取得し, 内部で自律システムに対応したコマンドに変換し, 自律システムに渡すところまでを担う. 自律システムでは BLE システムや EEG システムから受け取ったデータを元に, 目的地まで自律走行を行う.

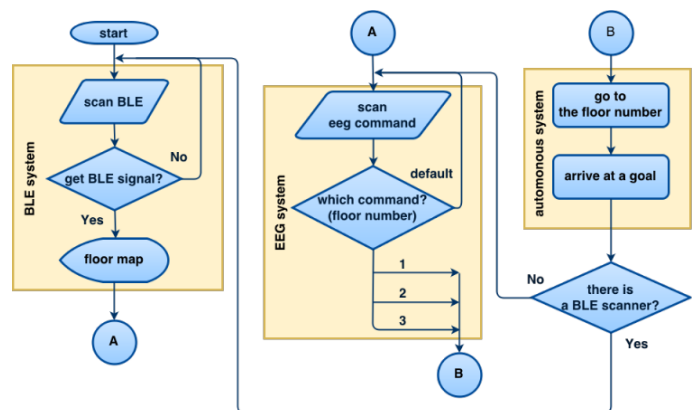


図 2 システムの流れ

表 1 BLE の設定

UUID	Major Identifier	Minor Identifier
建物名	階数	機器番号

2.3 目的地指定の仕組み

BLE 搭載のビーコン端末を使用した目的地指定について説明する [6]. 本研究の目的のひとつに利用者の負担軽減がある. そこで, 利用者が思考する方向の指定方法を既存研究の三方向指定から目的地指定にすることで負担の軽減を図る.

BLE にはセントラルとペリフェラルという 2 つの役割がある. ここでは, ビーコン端末がペリフェラル, PC がセントラルとなる. ペリフェラル側には主に UUID, Major Identifier, Minor Identifier を設定する. 今回, UUID は建物名を含めた半角英数字, Major Identifier は階数, Minor Identifier には機器番号を設定する (表 1).

各ビーコン端末に設定したパラメータをキーにして利用者が現在いるフロアを認識し、あらかじめ車いすによって生成された施設内の地図データと利用者に表示するための地図データ、その地図データにおける目的地となる地点の座標群を取得する。利用者へ視覚化する際には、目的地となる地点を地図データとともに数字で表示し、利用者の脳波から読み取るデータと紐付けることにより、目的地指定を実装している。




図 3 各フロアに設置するビーコン端末




図 4 利用者に表示する地図データ

各フロアに設置するビーコン端末を図 3 に、利用者へ表示する地図データを図 4 に示す。

3. インタフェースとしての脳波

車いすを制御するためのインタフェースとなる脳波について説明する。

利用者から脳波データを取得するためのハードウェアには、前述した Emotiv EEG を用いる。本研究の一つの目的として、利用者の負担軽減がある。そこで、利用者が思考する方向指定の方法を既存研究の三方向指定から目的地指定にすることで負担の軽減を図る。

利用者から脳波データを取得するためのハードウェアには、前述した Emotiv EEG を用いる。表 2 にハードウェアの仕様を示す。利用者の意図を学習するソフトウェアには Emotiv EEG SDK に含まれているアプリケーション (Emotiv Control Panel の Cognitiv Suite) を用いる。図 5 に、脳波データの取得に用いるハードウェアとソフトウェアを示す。

3.1 脳波データの学習と訓練

脳波を使用して車いすを動作させるまでに、脳波データの学習と訓練のフローを事前に行う必要がある。



図 5 脳波取得に用いるハードウェアとソフトウェア [3]

学習フェーズ

利用者の意図は、数字画像を思い浮かべることで車いすへのコマンドとして認識させる。そのため、学習は視覚情報や聴覚情報などのノイズを可能な限り削減するために暗室で行い、学習中、利用者は頭を動かしたり表情を変化させることなしに数字画像を見続け、イメージすることが重要となる。学習中に頭を動かしたり集中が途切れてしまったなど、理想的でないデータだと思った場合には同様のコマンドを再学習させる。今回、数字のパターン数は 1~3 までの 3 つとする。

訓練フェーズ

ここでは学習させたデータに対して、利用者がコマンドの出力に慣れるための訓練を行う。今回は、訓練に合計三時間程度実施した。訓練の様子イメージを図 6 に示す。



図 6 訓練の様子イメージ

3.2 脳波データの認識

学習・訓練を行った後、利用者の意図したものがどの程度正確に出力されているかを検証する。その際の認識率の測定方法について説明する。

測定方法は、利用者に対してランダムに数字画像を表示させ、取得した脳波コマンドに対してフィルタ処理をかけたものとの認識結果が同じかどうかをもって成功・失敗を判断する。この時、いずれかのコマンドが出力されるまで脳波コマンドの取得を試み続ける。従って、成功率と失敗率の和は 1 となる。

脳波コマンドの取得は、Emotiv EEG SDK を用いて行った。コマンドの出力数は学習させたパターン数だけ存在する。また、ここでのフィルタ処理とは Emotiv EEG SDK

表 2 ハードウェアの仕様?

Number of channels	14 (plus CMS/DRL references, P3/P4 locations)
Channel names	AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4
Sampling method	Sequential sampling. Single ADC
Sampling rate	128 SPS (2048 Hz internal)
Resolution	14 bits 1 LSB = 0.51 μ V
Bandwidth	0.2 - 45Hz, digital notch filters at 50Hz and 60Hz
Filtering	Built in digital 5th order Sinc filter
Dynamic range	8400 μ V (pp)
Coupling mode	AC coupled
Connectivity	Proprietary wireless, 2.4GHz band
Power	LiPoly
Battery life (typical)	12 hours
Impedance Measurement	Real-time contact quality using patented system

を使用したプログラムから得た最新 10 個の脳波コマンドのうち、あるコマンドが 80% を占めていた場合に利用者はそのコマンドを意図しているとしてシステムに認識されるというものである。図 7 にフィルタ処理の概要を示す。検証作業の試行回数は連続 10 回を 5 セットで、ノイズの少ない静かな部屋と生活音のある部屋で行った。

その結果、静かな部屋では 7 割弱の認識率、生活音のある部屋では 5 割の認識率となった。[7]




図 7 フィルタ処理の概要

4. 深層学習による脳波分析

前章では脳波データの認識率について、静かな部屋では 7 割弱、生活音のある部屋では 5 割であることを示した。通常利用時を考えると生活音のある部屋での認識率を向上させたい。そこで、認識率向上のために脳波の生データを用いて深層学習を行った。

4.1 深層学習

深層学習 (Deep Learning) とは、多層に重ねたニューラルネットワークを使用する機械学習である。深層学習は事前学習 (pre-training) と微調整 (fine-tuning) から構成される。事前学習は、入力層から順に各層において教師なし

学習を行う。微調整は、事前学習により構築された多層ニューラルネットワークに対して、正解データを元に予測結果のエラー誤差が小さくなるように調整を行う。図 8 に深層学習の全体像を示す。

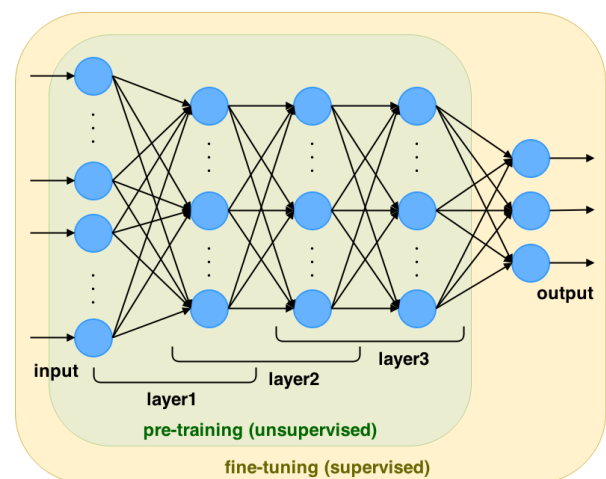


図 8 深層学習の全体像

4.2 前処理

利用者の脳波からコマンドが出ているかどうかを判断するには、脳活動とデルタ波の関係性 [8] に着目した。また、脳波の生データの取得には、Emotiv Testbench を使い、利用者が意識している数字画像が脳波として出ている箇所を抽出するために、デルタ波・シータ波・アルファ波・ベータ波の確認が可能な Emotiv EPOC Brain Activity Map を用いている。図 9 にそれぞれのソフトウェアを用いて取得した脳波全体の時系列グラフとデルタ波の反応の様子を示す。

4.3 計測方法

被験者成人男性 7 名に対して、1~3 の数字が表示される動画を視聴してもらうことによって計測する。

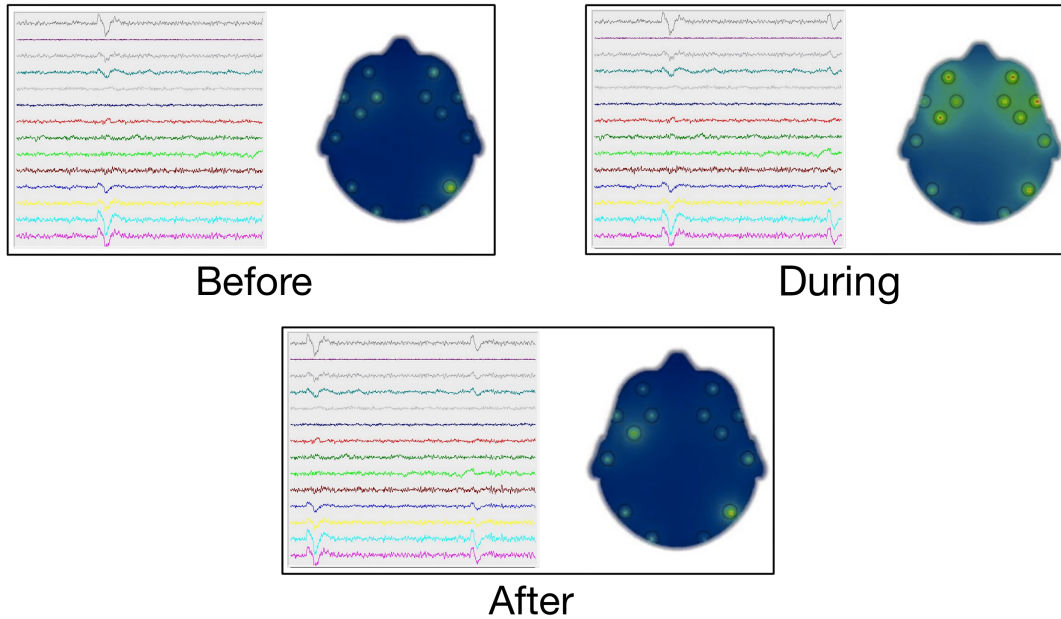


図 9 反応の様子

一つの動画の内容は次のようになる。動画の長さは 185 秒である。冒頭に 5 秒間黒地の画面が表示され、次に 15 秒間黒地に白色の文字で 1~3 のいずれかが表示され、また 5 秒間黒地の画面が表示される。これを 9 回繰り返す。

動画のパターンは 3 種類用意し、被験者一人ひとりにすべてのパターンを一度ずつ視聴してもらう。図 10 に動画のパターンを示す。動画中に表示される数字の順番を固定しないのは、被験者が数字の出る順番を記憶して、推測可能な状態にしないためである。




図 10 動画のパターン

4.3.1 データ・セットの作成

反応が起きていることを確認できた際に脳波よりコマンドが出ていると判断し、反応が起きてから 1 秒間を 1 つのデータとして抽出する。1 つのデータの長さは、 1608×1 となる。また、生データは計測した人によって電位が異なるため、抽出したデータ中の最大電位を 1、最小電位を 0 とする正規化を行う。その後、それぞれのデータの先頭に正解

*1 表 2 より、 14×129 [Number of channels \times Sampling rate].

ラベルをつけてデータセットの作成が完了する。今回は、合計 174 のデータ数となった。

4.4 事前学習

事前学習には Stacked Denoising Autoencoders(SdA) を用いる。Autoencoder(AE) は入力データを再現する出力データを得るためのパラメータを決定するものである。AE の入力の一部にノイズを付与して、より汎化能力を高めるものが Denoising Autoencoders (dA) である。今回用いた設定を反映した dA の処理の流れ [9] を説明し、図 11 に示す。

$$\tilde{x} \sim q_D(\tilde{x}|x) \quad (1)$$

AE で用いる入力 x を確率的マッピングにより \tilde{x} に破損させる。

$$y = s(W\tilde{x} + b) \quad (2)$$

破損した入力 \tilde{x} は、活性化関数 s に \tanh を用いて、 y を得るエンコーダとなる。重み行列 W の次元数は、入力層のユニット d \times 隠れ層のユニット d' となり、バイアス b の次元数は、隠れ層のユニット d' となる。

$$z = s(W'y + b') \quad (3)$$

y は \tanh を用いて、 z を得るデコーダとなる。 W' の次元数は線形ユニットで、バイアス b' の次元数は隠れ層のユニット d' となる。

$$L_H(x, z) = - \sum_{k=1}^d [x_k \log z_k + (1 - x_k) \log(1 - z_k)] \quad (4)$$

損失関数には、交差エントロピー誤差を用いて x と z の誤差が最小になるように計算される。そして、確率的勾配降下法 (SGD: Stochastic Gradient Descent) を用いて重みパラメータを更新しながら、終了基準に達するまで行う。

dA 単体より良い初期値を得るために、この dA を 3 層重ねて SdA として使用する。

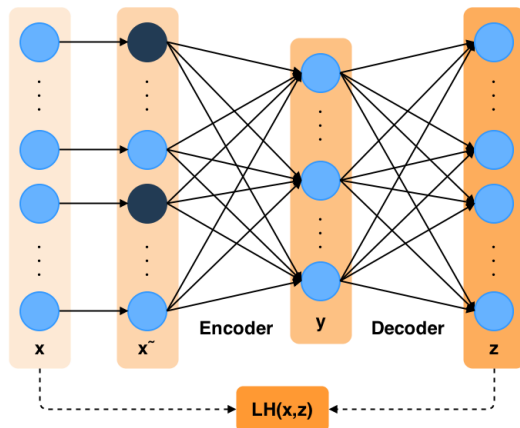


図 11 Denoising Autoencoders

4.5 微調整

ここでは、事前学習で得たパラメータを初期値にしてエラー誤差の微調整を行う。微調整には多層パーセプトロン (MLP: Multi-layer Perceptron) を用いる。

$$f(x) = G(b' + W'(s(b + Wx))) \quad (5)$$

G は出力層の活性化関数であり、Softmax を用いる。ここで 1~3 の 3 パターンにクラス分けをする。

5. 認識率

事前学習や微調整を行い識別器を作成する上で、さまざまなパラメータを調整する必要がある。今回は、隠れ層、エポック数、ノイズレベルを調整項目とし、いくつか実験を行った。表 3 に識別器のパラメータ調整と予測正答率を示す。また、予測正答率は、10000 回試行したものの平均である。

そのうち最も予測正答率の高かったネットワークの構造は、隠れ層が 1500-1500-1500、エポック数が 100-100-100、ノイズレベルが 0.3-0.3-0.3 で予測正答率は 80.41% となった。

6. 車椅子ロボットの自律走行

6.1 ハードウェア構成

走行系に電動車いす*2を用いており、外部からの操作のためのコントローラを使用し、PC と通信する。内界センサに電動車いすのホイールに内蔵したロータリーエン

*2 ヤマハ発動機株式会社。JW-アクティブ

コーダを用いた。外界センサとして、マップマッチング用の LRF*3

を設置高度 1.5[m] のセンサ架台に設置している。また、人物や障害物検出用の LRF*4 を左フットサポート下に設置している。本研究で使用するハードウェアの構成を図 12 に示す。



図 12 ハードウェア構成

6.2 自己位置推定

本研究で用いる車いすは、あらかじめ作成した環境地図上の自己位置を認識し、目的地までの経路を走行する環境地図ベースの自律走行機能と、走行経路上の障害物回避機能を併用した自律走行手法を用いている。目的地まで自律的に走行するために、自己位置を認識することが重要である。自己位置の認識には、車輪に内蔵されたロータリーエンコーダから取得できる情報からデッドレコニング [10] により行うが、長距離を走行した場合に誤差が累積する。本研究では、あらかじめ、車いすロボットを手動操作して環境地図を生成する。作成した環境地図と、自律走行時に取得できる局所的な環境地図をマッチングし、この誤差の補正を行う。マッチングアルゴリズムに Iterative Closest Point (ICP) [11] アルゴリズムを用いており、常に環境地図上の自己位置を認識している。そして、後述する自動経路

*3 北陽電機株式会社 UTM-30LX-EW

*4 北陽電機株式会社。UBG-04LX-F01.

表 3 識別器のパラメータ調整と予測正答率

	A	B	C	D	E	F	G	H	I
L1 / Hidden Layer	800	1500	1500	1500	1500	1500	1800	1800	1800
L1 / Epoch	100	100	100	200	200	200	100	100	100
L1 / Corruption Level	.3	.3	.3	.3	.3	.1	.3	.3	.1
L2 / Hidden Layer	800	1500	1500	1500	1500	1500	1800	1800	1800
L2 / Epoch	100	100	100	200	200	200	100	100	100
L2 / Corruption Level	.3	.3	.4	.3	.4	.2	.3	.4	.2
L3 / Hidden Layer	800	1500	1500	1500	1500	1500	1800	1800	1800
L3 / Epoch	100	100	100	200	200	200	100	100	100
L3 / Corruption Level	.3	.3	.5	.3	.5	.3	.3	.5	.3
MLP / Epoch	25	25	25	25	25	25	25	25	25
Predict (%)	69.81	80.41	80.27	62.40	66.20	69.72	61.38	66.37	78.42

設計処理により求められた通過点を辿り、現在地から最終目的地まで自律走行する。図 13 に本研究で生成した環境地図を示す。




図 13 生成した環境地図

6.3 障害物回避

車いすの障害物回避機能には車いすの左フットサポートの下部に設置した LRF を用いる。この LRF は地面から 0.1[m] の位置に地面に対して 3.0 deg 下向きに仰角を持たせて固定している。そのため LRF の設置高度以下の障害物を検出することが可能である。図 14 に示すように、車いす前方に 1.5[m] 四方の障害物検出エリアを設定し、このエリア内に障害物を検出すると回避行動をとる。また、前方 0.5[m] 以内に障害物を検出した際は 3 秒間停止する。3 秒後も検出し続けられれば回避行動をとる。これは歩行者などが検出エリアに立ち入った際に有効である。回避方法は非常に単純で、車いす前方から左右のエリアを比較し、より広いエリアの方向へ移動するように走行する。障害物を検出しなければ通常の自律走行処理へ戻る。

6.4 自動経路設計

今回用いる経路設計手法 [12] のベースとなる手法は、環境地図上の走行可能領域にランダムなノードを追加してグラフ構造を作り、ダイクストラ法を用いて最終目的地までの最短距離となるノードを辿る経路を求めるというものである。ダイクストラ法の計算コストは $O(n^2)$ であり、経路候補となる n 個のノード数が計算量に影響する。そこで本




図 14 障害物回避エリア

研究では、ノードの生成方法を工夫し、必要最低限のノード数で到達可能な経路を設計する手法を用いた。以下にノード追加方法を示す。

- (1) 環境地図中の障害物に対し、電動車いすロボットの最小旋回半径の分、膨張処理を行う。これはノードを作成した箇所に車いすロボットの旋回中心点が通過するため、実質的な走行不可能領域を障害物とするためである。
 - (2) 環境地図の全域に図 15 のマスクパターンを走査して当てはめ、マッチした画素の座標にノードを追加する。これで環境地図上の障害物の角にノードを追加することとなる。
 - (3) 障害物が丸みを帯びている場合、環境地図上では多角形として表され、2 の処理でノードが密集する。そこで一定間隔でノードを除去することで計算量を抑える。
- 経路設計手法の比較のため、仮想的な環境地図を用いて実験を行った。図 16 にランダムに 200 個のノードを追加した従来の方法で生成した経路を示す。図 17 に今回提案した手法による経路設計結果を示す。今回用いた手法によ




図 15 走査するマスクパターン

り、必要最低限のノード数で出発地点から目的地までの最短経路が設計できていることがわかる。

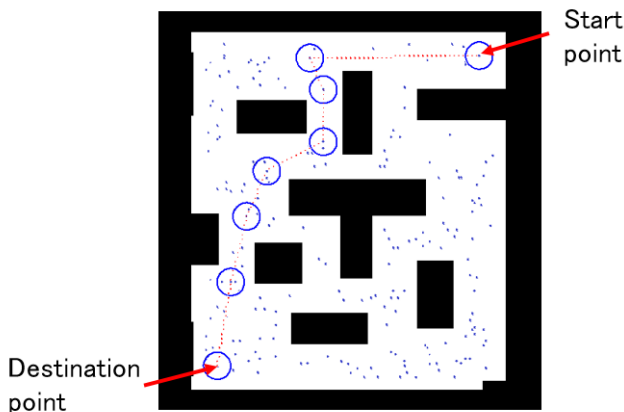


図 16 従来手法での経路設計結果

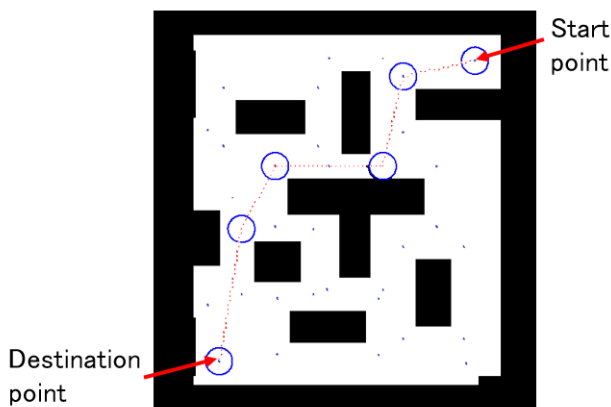


図 17 今回用いた手法での経路設計結果

7. おわりに

本研究では、脳波をインタフェースとした車いすロボットの制御に目的地指定という方法をとった。これにより、従来の三方向指定と比べて利用者への負担や安全性の問題を解決することができる。また、本手法と従来手法を組み合わせることにより、より実用的なシステムを構築することが期待できる。

脳波の認識率については、製品のソフトウェアを用いた

場合に生活音のある部屋では 5 割、静かな部屋では 7 割弱であったが、深層学習を用いることにより 8 割となり、深層学習が適用可能であることを示した。今後は、脳波コマンドの認識パターン数を増加させることや、認識率を高めるために深層学習の手法の模索やパラメータの調整を行い、通常利用において利用者が不快感を抱かないほどに向上させる必要がある。

自律走行においては、あらかじめ作成した環境地図を元に自律走行するが、自己位置を認識する精度が低く実環境との誤差が大きい。また、現時点では、あらかじめ作成する環境地図のマッチングを自動的に行うことができるが、歪みが多く最終的に手作業によって修正しなければならない。そのため、新しい走行環境への対応に時間がかかる問題がある。この解決のため、自己位置推定と環境地図生成を同時に行う Simultaneous Localization and mapping (SLAM) [13] の導入を予定している。

参考文献

- [1] 長谷川良平: ブレイン-マシンインタフェースの現状と将来. 電子情報通信学会誌, Vol. 91, No. 12, pp. 1066-1075, dec 2008.
- [2] 唐山英明. 第 41 回 BMI と BCI : 究極のヒューマンインタフェース (知っておきたいキーワード). 映像情報メディア学会誌: 映像情報メディア, Vol. 63, No. 6, pp. 772-776, jun 2009.
- [3] Emotiv. 入手先 (<http://emotiv.com/epoc.php>).
- [4] Giorgio Ganisa, William L. Thompsona, Stephen M. Kosslyn: Brain areas underlying visual mental imagery and visual perception: an fMRI study, Cognitive Brain Research 20 (2004) 226-241
- [5] 脳波で電動車いすをリアルタイム制御 入手先 (<http://www.riken.jp/pr/press/2009/20090629/>), 2009
- [6] 鄭立: Bluetooth LE 入門スマホにつながる低消費電力無線センサの開発をはじめよう. 秀和システム, 2014.
- [7] 鷹箸孝典, 阿部拓真, 中沢実: 脳波を用いた車いすロボット制御システム, 情報処理学会, インタラクション 2015, 684-687, 2015
- [8] Martin Schurmann, Canan Basar-Eroglu, Vasil Kolev, Erol Basar: Delta responses and cognitive processing: single-trial evaluation of human visual P300. International Journal Psychophysiology, Vol. 39, pp. 229-239, jan 2001.
- [9] Pascal Vincent, Hugo Larochelle, Isabelle Lajoie, Yoshua Bengio, and Pierre-Antoine Manzagol: Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion. Vol. 11, pp. 3371-3408, December 2010.
- [10] Peter Corke: Robotics Vision and Control. Springer, 2011.
- [11] 八木康史他: コンピュータビジョン最先端ガイド 3. アドコム・メディア株式会社, 2010.
- [12] 阿部拓真, 中沢実: 自律搬送車における効率的経路制御の設計と実験. 平成 26 年度電気関係学会北陸支部連合大会. 公演論文集, sep 2014.
- [13] Sebastian Thrun, Wolfram Burgard and Dieter Fox, 上田隆一 (訳): 確率ロボティクス. 毎日コミュニケーションズ, 2007.