

14th SICE Symposium on Computational Intelligence

December 22-23, 2018, Saga

第 14 回コンピューターショナル・インテリジェンス研究会

講演論文集

期 日：2018 年 12 月 22 日(土)，23 日(日)

会 場：佐賀大学 本庄キャンパス

**SICE**<sup>®</sup>

主 催：計測自動制御学会 システム・情報部門

共 催：計測自動制御学会 九州支部

企 画：コンピューターショナル・インテリジェンス部会，知能工学部会

協 賛：システム制御情報学会，日本知能情報ファジィ学会，進化計算学会，電気学会，  
情報処理学会，日本神経回路学会，日本機械学会，人工知能学会，ヒューマ  
ンインタフェース学会，電子情報通信学会，IEEE Computational Intelligence  
Society Japan Chapter (CISJ)，IEEE Systems, Man, and Cybernetics Society Japan  
Chapter

著作権 © 2018

公益社団法人計測自動制御学会(SICE)  
〒101-0052 東京都千代田区神田小川町 1-11-9 金子ビル 4 階

カタログ番号 18 PG 0011

著作権は、計測自動制御学会がもっている  
ので、個人の使用のための複製以外の  
目的で掲載の記事の一部または全文を  
複製する場合には、著作権者に許可を求  
め規定の複製料を支払うこと。

発行日：2018年12月22日

発行者：公益社団法人計測自動制御学会 システム・情報部門  
コンピューターショナル・インテリジェンス部会， 知能工学部会

## 第14回コンピュータショナル・インテリジェンス研究会プログラム

12月22日(土)

13:30~14:45 (3件) 司会 畠中 利治 (大阪大学)

- 1 災害現場の情報を把握する自律AIドローンの研究開発 1  
○脇山 晃希, 時津 颯麻, 岡崎 泰久, 中山 功一 (佐賀大学)
- 2 敵対的生成ネットワークによる経路計画 7  
○石橋 正太郎, 泉 清高, 辻村 健 (佐賀大学)
- 3 対話ロボットの自然な“あいづち”に向けた研究 11  
○野柳 晴華, 大島 千佳, 中山 功一 (佐賀大学)

15:00~16:20 (3件) 司会 中島 智晴 (大阪府立大学)

- 4 Projection-basedビジュアルサーボ法を用いた複数対象物中指定対象物の実時間認識 16  
○寇 ギョウ郡, 田 宏志, 李 想, 戸田 雄一郎, 松野 隆幸, 見浪 護 (岡山大学)
- 5 会話中の単語をもとにオートサジェスト機能を使って検索した画像の提示方法 24  
柴田 大輔, 山口 裕, ○大島 千佳, 中山 功一 (佐賀大学)
- 6 ニューラルネットワークの埋め込み安定性と汎化能力の関係 29  
○古庄 泰隆, 池田 和司 (奈良先端科学技術大学院大学)

16:30~17:50 クリフォード代数の情報表現能力とその応用 WG 企画

特別講演 金谷一朗先生 (長崎県立大学シーボルト校)

「CGアニメーションにおけるクォータニオンの応用」

12月23日(日)

9:30~10:45 (3件) 司会 中山 功一 (佐賀大学)

- 7 ディープラーニングによる牛の妊娠鑑定 34  
○井手 祐太, 中山 功一 (佐賀大学), 山下 健一 (産業技術総合研究所), 福田 修 (佐賀大学)
- 8 深層畳込み生成敵対ネットワーク DCGAN で生成した旋律を人はどのように感じるか 42  
○高木 雄太, 橋 完太 (工学院大学)
- 9 欠損値のない学習用データが利用可能な場合における欠損値に対してロバストな学習法 47  
○福島 卓弥, 長谷川 拓, 中島 智晴 (大阪府立大学大学院)

10:50~12:10 Invitation to Computational Intelligence Fons Scientiae Project

13:20~14:30 (3件) 司会 磯川 悌次郎 (兵庫県立大学)

- 10 半導体アレイセンサとニューラルネットワークを用いた臭い識別システムの構築 54  
○岸田 直也, 磯川 悌次郎, 松井 伸之, 湯本 高行, 上浦 尚武 (兵庫県立大学)
- 11 乳房X線画像における画像診断が難しい腫瘍に対する深層学習を用いた良悪性鑑別の試み 58  
○野呂 恭平 (東北大学), 張 暁勇 (仙台高等専門学校), 高野 寛己, 市地 慶 (東北大学),  
柳垣 聡, 高根 侑美 (東北大学病院), 石橋 忠司, 本間 経康 (東北大学)
- 12 等価ペナルティ係数法を導入した差分進化による制約付き最適化 62  
○高濱 徹行 (広島市立大学), 阪井 節子 (広島修道大学)

14:45~16:00 (3件) 司会 泉 清高 (佐賀大学)

- 13 ロボット'CATARO'を使った被介護者の異常検知 68  
○田中 竜二, 大島 千佳, 中山 功一 (佐賀大学)
- 14 複数 Android 端末の分散制約充足アルゴリズムによる協調 73  
○田川 来夏, 上田 俊 (佐賀大学)
- 15 交通事故時の移動モード判別アルゴリズムの実装 77  
○塚本 安記規, 大島 千佳, 中山 功一 (佐賀大学)



# 災害現場の情報を把握する自律 AI ドローンの研究開発

○脇山晃希, 時津颯麻, 岡崎泰久, 中山功一 (佐賀大学)

## AI Drone for Collection Data at a Disaster Scene

\* K. Wakiyama, S. Tokitsu, Y. Okazaki and K. Nakayama (Saga University)

**Abstract**— The frequent natural disasters in recent years indicate a need for strategies that will allow rapid information gathering and analysis of victims at the disaster site. Therefore, in this paper, we constructed an autonomous flight AI drone system that gathers and analyzes the victims by using image processing.

**Key Words:** AI drone, image processing, rescue support system, counter disaster

### 1 はじめに

近年, 数多くの災害が発生している。「防災力の鍵」となる重要な情報として, 実際の現場を把握できるデータや映像がある<sup>1)</sup>. 本研究では, 災害現場の状況をリアルタイムに把握するための人工知能 (AI) ドローンシステムに向けて, 以下の2つの課題に取り組む.

#### <課題1: 自律飛行の実現>

大規模災害では, 災害現場の近くに近づけない場合も多い. また, 多数の人が災害現場に向かうことが, 救助活動の妨げになる場合もある. 従来の市販のドローンは, 操縦者が送信機を持って飛行地域の3km程度まで近づく必要があった. このため, 遠隔地の災害情報を把握することが難しい. 本研究では, 送信機から送られてくる操縦者の指示に従って飛行するのではなく, ドローンが自律して飛行する AI ドローンを実現する.

#### <課題2: 画像処理による状況把握>

大規模災害では, 災害現場の映像を人間がくまなく見て把握するような時間的余裕がない. そのため, ドローンが飛行して大量の映像が集まっても, 即座に状況を把握することは困難である. 本研究では, ドローンが撮影した映像を, 自律 AI ドローンおよびオンラインサーバが画像処理し, 災害現場把握に有益なデータを作成するシステムを実現する.

### 2 画像処理による状況把握

本研究では, ドローンのカメラによって得られた動画や静止画から, 災害状況把握に有益なデータを作成するシステムの開発を行う. なお, 現段階では, AIドローンに機能を実装する前の動作試験として, DJI Mobile SDK<sup>2)</sup>を用いた自動飛行プログラムを開発する.

#### 2.1 Pix4Dmapper による 3D モデル生成

##### 2.1.1 Pix4D

本研究では, 災害状況把握に有用なデータを作成する手段として, Pix4Dmapperを用いる. Pix4Dmapperとは, Pix4D社が有償で提供している写真測量ソフトウェアである. Pix4Dmapperの主な機能として, 撮影した複数の画像から点群・三次元地形モデルを作成する機能がある. ドローンで撮影した静止画を入力画像とし




Fig. 1: Flight plan.

てPix4Dmapperに与えると, 災害現場の3Dモデルを作成することができる. この時, 高精細な3Dモデルを生成するためには, 適切な位置から撮影を行う必要がある. 本研究では, 3Dモデル生成のための自動で撮影を行うプログラムを開発する.

##### 2.1.2 撮影方法

Pix4Dmapperを用いて, 高精細な3Dモデルを生成するのに適した撮影方法の図解をFig. 1に示す. ドローンはFig. 1中の黄色の矢印の位置から飛行を開始し, 矢印の向きに進みながら, 赤点の位置で撮影を行う. この時, 進行方向の重なりであるfrontal overlapは75%以上である必要があり, 進行方向と垂直な向きの重なりであるside overlapは60%以上である必要がある<sup>3)</sup>. また, frontal overlap, side overlapともに, 割合が高いほど高精細な3Dモデルが作成できる. 本研究では, 高精細な3Dモデル作成のための撮影方法 (以下, 「90%lap」と示す.) と, 撮影時間を短くする撮影方法 (以下, 「12shoot」と示す.) の2つを実装した. その内容を以下に示す.

##### <手法1: 90%lap>

この手法では, frontal overlap, side overlapともに90%とし,  $5 \times 4$ で合計20回撮影を行う. 手法の図解をFig. 2に示す. ドローンは黄色の矢印の位置から飛行を開始し, 矢印の向きに進みながら赤点の位置で撮影を行う.

##### <手法2: 12shoot>

この手法では, frontal overlapを80%, side overlapを60%とし,  $4 \times 3$ で合計12回撮影を行う. 手法の図解をFig. 3に示す. ドローンは黄色の矢印の位置から飛行を




Fig. 2: 90%lap




Fig. 3: 12shoot

開始し、矢印の向きに進みながら赤点の位置で撮影を行う。

### 2.1.3 実験結果

作成したプログラムを用いてドローンを自動飛行させ撮影を行った。撮影にはDJI製のドローンPhantom4を用いた。高度8mから90%lapと12shootそれぞれの撮影方法によって得られた静止画を入力画像として、Pix4Dmapperで3Dメッシュモデルと点群データを作成した。作成した3Dメッシュモデルのキャプチャ画像をFig. 4, Fig. 5に示す。作成した点群データのキャプチャ画像をFig. 6, Fig. 7に示す。



Fig. 4: 3D model by 90%lap.



Fig. 5: 3D model by 12shoot.




Fig. 6: Point cloud data by 90%lap.




Fig. 7: Point cloud data by 12shoot.

また、高度を25mに変更して、2つの撮影方法それぞれを用いて撮影を行い。離陸開始から撮影終了までにかかった時間を計測した。90%lapでの撮影は、2分15秒程かかり、12shootでの撮影は、1分46秒ほどかかった。

### 2.1.4 考察

実験の結果、本手法による撮影で得られた静止画から、3Dメッシュモデルと点群データを問題なく作成できることが分かった。また、90%lapにより作成された3Dモデルは、12shootによるものよりも高精細であった。特に、Fig. 7の人体の部分に注目してみると、判別が困難なほど形が崩れていた。2つの手法の撮影所要時間に大差がないことから、撮影枚数が少ない場合は、overlapを大きく設定することが望ましいと考えられる。

90%lapによる撮影では、車と人体を容易に認識できる程高精細な3Dモデルを作成することができた。このことから、90%lapは、事故現場の状況を把握するための撮影手法として、十分活用可能であると考えられる。

12shootによる撮影では、人体などの小さい対象の3次元的認識は難しいが、構造物や地形の認識は十分に可能な程度の3Dモデルを作成することができた。このことから、12shootは、事故現場周辺の状況を広く把握するための撮影手段として、十分活用可能であると考えられる。



## 2.2 OpenPose による人体識別

### 2.2.1 OpenPose

本研究では、ドローンのカメラによって得られた静止画から、災害状況把握に有益なデータを抽出する手段として、OpenPose<sup>4)</sup>を用いる。OpenPoseとは、画像処理によって、人間の姿勢を推定し、それをボーン構造で可視化するソフトウェアである。入力データとしては、動画と静止画が使用可能であるが、今回は、静止画のみを入力とする。

### 2.2.2 処理の流れ

ドローンのカメラによって得られた静止画を入力として、OpenPoseの出力画像を表示するまでのデータの流れをFig. 8に示す。ドローンのカメラで撮影された静止画は、まず、プロポに接続したAndroid端末に送信される。静止画を受け取ったAndroid端末は、HTTP通信で、その静止画をサーバに送信する。それを受け取ったサーバは、LAN内の画像処理用の高性能PCへ受け取った静止画を送信し、画像処理のリクエストを送る。画像処理用の高性能PCは、受け取った静止画をOpenPoseに入力し、その処理結果をサーバへ送信する。

### 2.2.3 表示方法

OpenPoseの処理結果は、サーバに保存される。保存されたデータは、サーバスクリプトを用いてブラウザに表示する。サーバスクリプトでは、画像表示のために、JavaScriptのプラグインbaguetteBox<sup>5)</sup>を使用した。ブラウザには動的に生成されたサムネイル画像が並べて表示され、サムネイルをクリックすると拡大表示される。拡大表示画面では、前後の画像への切り替えボタンと、サムネイル画面へ戻るボタンが表示される。

### 2.2.4 実験結果

ドローンで手動撮影を行い、2.2.2の処理の流れに従ってデータを作成し、ブラウザで表示した。ドローンで手動撮影した静止画をFig. 9に、処理結果が表示されたブラウザ画面のサムネイル表示・拡大表示をそれぞれFig. 10, Fig. 11に示す。撮影にはDJI製のドローンInspire1とDJI製のカメラZenmuse X3を用いた。

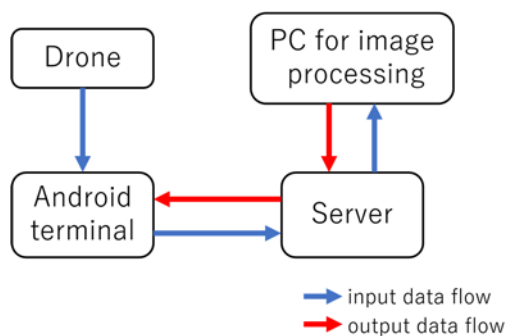


Fig. 8: Data flow.



Fig. 9: Photo taken by drone.



Fig. 10: Thumbnail display.



Fig. 11: Zoom display.

### 2.2.5 考察

実験の結果、ドローンで上空から撮影した静止画を、サーバを介してOpenPoseで処理し、その処理結果をAndroid端末で表示することができた。Fig. 11の処理結果を見てみると、人体を問題なく識別できることが分かった。このことから、本手法は、ドローンの空撮による静止画から、素早く人体を識別・認識できるデータを作成する手段として有用であると考えられる。

撮影対象との距離が遠くなると、OpenPoseの認識率の低下や、誤認識が生じるため、高高度からの撮影においては人体の識別に問題がある。しかし、これは画像サイズを拡大することで解決可能であるため、Android端末側のプログラムやサーバ側のスクリプトの変更で対処可能であると考えられる。

### 3 Raspberry Piによる自律飛行

ドローンの自律飛行を実現するため、本研究ではシングルボードコンピュータであるRaspberry Pi と、DJI社より提供されているDJI Onboard SDK<sup>6)</sup>、画像処理ライブラリであるOpenCV<sup>7)</sup>を利用し、画像判別によるドローンの自律飛行制御システムを開発する。

#### 3.1 ドローンの制御方法について

ドローンは通常、送信機を用いて飛行制御を行うが、DJI社のドローンは自動飛行の手段としてDJI Mobile SDK及びDJI Onboard SDKが提供されている。これらは相互に通信を行うことが可能であり、連携させることでより高度な飛行制御が可能となる。

#### 3.2 DJI Mobile SDKとDJI Onboard SDK

DJI Mobile SDKはDJI社によって提供されているドローンの飛行補助ソフトウェア開発キットである。ドローンを操作する送信機に携帯端末をUSB接続し、携帯端末上でアプリケーションを操作することでドローンに飛行およびカメラ制御を行わせることが可能となる。

DJI Onboard SDKはDJI社の特定機種のだローンにコンピュータを搭載し、搭載されたコンピュータ上で動作するC++プログラムによる飛行制御・カメラ制御を可能にするソフトウェア開発キットである。

DJI Mobile SDKによる飛行プログラムは携帯端末上で動作し、携帯端末上のプログラムからの飛行命令をUSB接続された送信機経由でドローンに送信して飛行制御を行う。そのため飛行指示にはドローンと送信機が接続可能な距離内になければならず、ドローンのカメラを用いて画像を撮影してもその画像をその場で処理し、飛行制御に反映させるといったことができない。

一方、DJI Onboard SDKによる飛行プログラムはドローン本体に搭載されたコンピュータ上のプログラムから有線接続でドローンに直接命令が可能であるため、ドローンが送信機との接続が可能な範囲外であっても自律的な飛行制御が可能である。また、ドローンに搭載されたコンピュータ内で画像処理を行うことで、その結果を飛行制御に反映させ、必要な情報を効率的に取得することができる。

これらの点から、本研究では遠隔地で自律飛行し、画像処理によって必要な情報を取得するためにDJI Onboard SDKを用いたドローンの自律飛行制御システムを開発する。

#### 3.3 Raspberry Pi

Raspberry PiはRaspberry Pi財団によって開発されたARMプロセッサを搭載した教育用に開発されたシングルボードコンピュータである。microSDカードをストレージとして利用し、LinuxOSを利用可能である。また、カメラやセンサ等の機器を接続可能であり、拡張性にも優れている。本研究では、Raspberry Pi専用カメラモジュールを接続し、OpenCVとDJI Onboard SDKを



Fig. 12: Raspberry Pi 3 Model B+.

導入して画像処理と飛行制御を行う。今回利用したRaspberry Pi 3 Model B+の外観をFig.12に示す。

##### 3.3.1 OpenCV

OpenCVはIntelが開発したコンピュータビジョン向けのオープンソース・ライブラリである。本研究では、OpenCVの画像処理機能を用いてドローンからの空撮画像を解析し、飛行制御に反映する。

##### 3.3.2 Raspberry Pi専用カメラモジュール

DJI Onboard SDKでは、ドローンに接続されたカメラで撮影された画像を搭載コンピュータが取得する機能が標準でサポートされていない。このため、Raspberry Piに専用のカメラモジュールを接続し、ドローンに搭載することでRaspberry Piの画像取得を可能にし、取得した画像を処理することによる飛行経路の制御を可能とする。

Raspberry Pi専用カメラモジュールの標準動作環境はShellおよびPythonであるため、DJI Onboard SDKの動作環境であるC++で動作させるために、OpenCVでRaspberry Pi専用カメラモジュールを利用可能になるライブラリ「RaspiCam\_CV<sup>8)</sup>」を用いている。

#### 3.4 システムの概要

##### 3.4.1 ソフトウェアの動作

Raspberry Piから制御信号を送信して飛行させる。飛行中にカメラモジュールの画像を取得し、OpenCVによって画像処理を行い、撮影対象を探索する。画像内に撮影対象を検出した場合、撮影対象が真下に来るようにドローンを飛行させ、カメラモジュールおよびドローン付属カメラで撮影を行い、帰還する。飛行プログラムはRaspberry Pi起動時に自動実行される。

現在、自律飛行制御および画像認識の単体動作、および複合時の動作テストが完了している。画像処理と飛行制御の複合動作が今後の課題である。






Fig. 13: Raspberry Pi mounted DJI Matrice100.

### 3.4.2 ハードウェア構成

カメラモジュールを接続したRaspberry PiとDJI社のドローンDJI Matrice100をUSBシリアル変換モジュールを経由してRC-232で有線接続する。Raspberry Piを搭載したDJI Matrice 100をFig. 13に示す。Raspberry Pi本体はドローン上部に格納する。専用カメラモジュールはRaspberry Piと専用ケーブルで接続してドローン下部に固定し、Raspberry Piの電源はドローンの電池から獲得している。

## 4 構築する災害状況把握システム

本研究では、AIドローン・画像処理システム・サーバを組み合わせる構築される災害状況把握システムを提案・開発する。このシステムによって、プロボの電波が届かない遠距離の災害現場の状況を、複数同時に、円滑に把握することが可能になる。

### 4.1 システムの構成

災害状況把握システム全体の構成をFig. 14に示す。このシステムでは、1台のサーバが複数のAIドローンを管理する。サーバは、ドローンに離着陸とミッションの実行を指示する。サーバからの指示は、HTTP通信でAIドローンのRaspberry Piへ送られる。指示を受けたRaspberry Piは、指示を解析し、内容に沿ったミッションを実行する。ドローンはRaspberry Piの制御により自律飛行を行う。このようにして、各AIドローンは1台のサーバにより間接的に制御される。現時点では、Raspberry Piは、Wifiを用いてネットワーク接続する想定である。

### 4.2 システムの実装方法

災害状況把握システムは、DJI Onboard SDKとPHPによるサーバスクリプト、MySQLによって実装を行う。災害状況把握システムの具体的な実装方法をサーバ側とAIドローン側に分けて以下に示す。

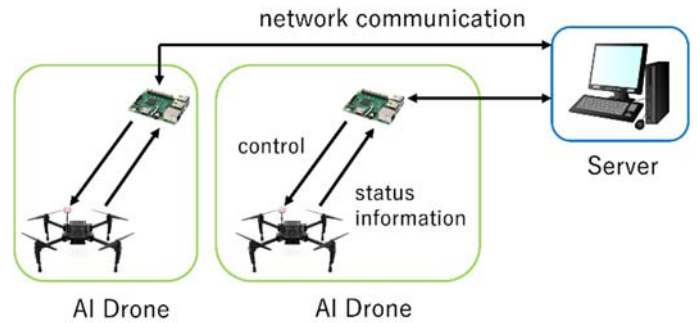


Fig. 14: System architecture.

#### 4.2.1 サーバ側

サーバ側で実装する基本的な機能は、命令データの更新とログファイルの作成である。

サーバからAIドローンへ送られる命令データは、MySQLを用いて管理される。各AIドローンには、固有の識別番号を設定しておき、この識別番号とミッションの種類、目的地の座標や高度、ミッションの重要度などをひとまとめたものが命令データとなる。ブラウザでの操作やプログラムなどにより新たな命令が指示された時、サーバは、MySQL上の命令データのテーブルを更新する。それと同時に、新たな命令の内容をテキストファイルに追記していくことで、命令のログファイルを作成する。

また、ドローンのステータスも命令データと同じように、MySQLを用いて管理される。AIドローンから送られてくるステータス情報（座標やバッテリー残量、ミッションの実行状況など）を識別番号と紐づけて、MySQL上のドローンステータスのテーブルを更新する。それと同時に、AIドローンから送られてきたステータス情報をテキストファイルに追記していくことで、ドローンステータスのログファイルを作成する。

このようにして、サーバ側では、最新の命令データと最新のドローンステータス、ログの管理を行う。

#### 4.2.2 AIドローン側

AIドローン側は、3章で述べた自律飛行システムを基本として実装する。Raspberry Piの飛行プログラムが起動するとまず待機状態に入る。待機状態では、数秒に1回サーバに識別番号をPOST送信し、返ってくる命令データを保存する。新しく受け取った命令データが、前回のものから更新されていれば、その命令に従って次のミッションを実行する。一定回数命令データの更新が行われなければ、自動で帰還する。

自律飛行プログラムには、予め複数のミッション（静止画の撮影や離着陸、待機など）を作成しておく。Raspberry Piは命令データの内容を解析して、次に実行するミッションを決定する。ミッションを実行した後は、再び待機状態に入る。

さらに、Raspberry Piは、待機中やミッションの開始前、ミッションの終了後などのタイミングでドローンのステータス情報を取得して、識別番号と共にサーバへPOST送信する。

### 4.3 システムの利点

本研究で提案する災害状況把握システムは、1台の端末（サーバPC）で複数のAIドローンを制御可能であるという利点を持つ。これは、単純に一人が複数のドローンを扱いやすくするだけでなく、AIドローン同士が互いの状態（座標やバッテリー残量、ミッションの実行状況など）を把握できるということを意味する。例えば、システムの管理下にあるAIドローンが全てミッションの実行中である時に、新たな災害現場へドローンを向かわせる必要性が生じた場合を考えると、各AIドローンの現場までの距離、バッテリー残量、現在実行中のミッションの重要度などから、その現場へ向かわせるのに最も適したAIドローンを選択して、指示を出す、といったことが可能になる。

また、サーバを介してドローンを制御するという性質上、他のシステム（事故を検知して座標をサーバに送信するアプリなど）との連携が容易であるという利点も持っている。この事から、災害状況把握システムによって複数のAIドローンを制御することは、災害状況の円滑な把握につながると考えられる。

### 4.4 データの表示

本研究で提案する災害状況把握システムでは、各AIドローンの状態やドローンのカメラによって得られた動画・静止画は、サーバに保存される。このデータを用いれば、Google Maps API<sup>9)</sup>などを利用して、MAP上に各AIドローンの現在地、ドローンの飛行の軌跡、各災害現場の静止画などを表示することが可能である。

## 5 おわりに

本研究では、自律して飛行するAIドローンを実現した。加えて、画像処理により、災害状況の把握に有用なデータを作成する2つのシステムを実現した。これにより、ドローンを用いた、災害現場周辺を3次元的に把握できる3Dモデルの作成や、素早く人体を識別・認識できる画像の作成が可能となった。しかし、これらのシステムと自律飛行プログラムは独立しており、また、これらのシステム同士も独立している。そのため、現時点では、局所的な場面でしか活用できない。そこで、システムを総合的に運用するために、4章で述べた災害状況把握システムとして統合する必要がある。

災害状況把握システムが実現できれば、複数の場所で次々に発生する災害の状況を円滑に把握することが可能になると考えられる。

## 参考文献

- 1) 中村 孝之 “無人航空機 (UAV) を活用した国土地理院の災害対応”, 北海道測量技術講演会, 2017年: <http://www.gsi.go.jp/common/000150883.pdf>
- 2) DJI Mobile SDK Documentation: <https://developer.dji.com/mobile-sdk/documentation/introduction/index.html>
- 3) Pix4Dmapper Image acquisition: <https://support.pix4d.com/hc/en-us/articles/115002471546-Image-acquisition>
- 4) OpenPose: <https://github.com/CMU-Perceptual-Computing-Lab/openpose>
- 5) baguetteBox: <https://github.com/feimosi/baguetteBox.js>
- 6) DJI Onboard SDK Documentation: <https://developer.dji.com/onboard-sdk/documentation/introduction/homepage.html>
- 7) Opencv: <https://opencv.org/opencv-4-0-0.html>
- 8) Raspicam\_CV: [https://github.com/robidouille/robidouille/tree/master/raspicam\\_cv](https://github.com/robidouille/robidouille/tree/master/raspicam_cv)
- 9) Google Maps API: <https://cloud.google.com/maps-platform/?hl=ja>

# 敵対的生成ネットワークによる経路計画

○石橋正太郎 泉清高 辻村健 (佐賀大学)

## Path Planning Using Generative Adversarial Networks

\*S. Ishibashi, K. Izumi and T. Tsujimura (Saga University)

**Abstract**— In this paper, we propose an obstacle avoidance route of mobile robot using Generative Adversarial Networks. Generative adversarial networks consists of two networks, a generation network and a discrimination network. The generator learns to generate data that tricks discriminators. Discriminator learns to correctly discriminate real data and data generated by generator. Learn two network models and output the desired path by inputting [obstacle map, start point, end point] to the generation network. In addition, we use the route generated by the RRT\* algorithm as learning data. By using the RRT\* algorithm, it is easy to secure a large amount of learning data in deep learning. We evaluate and examine whether the route generated by the proposed method is the correct route.

**Key Words:** Generative Adversarial Networks, Path Planning

### 1 はじめに

移動ロボットは障害物を回避しながら目的の位置まで移動し様々なタスクを遂行するため、障害物を考慮した経路計画は重要な研究課題である。経路計画のためのアルゴリズムには Rapidly-exploring Random Tree(RRT)<sup>1)</sup> やダイクストラ法<sup>2)</sup> などがある。一般にこれらの手法は計算コストが高いため、計算時間が十分でない場合に冗長な経路を計画する問題がある。また、乱数により枝状に経路を探索していくので経路は探索するたび変わり、以前に計画した経路を再利用し、経路計画するような仕組みはない。これらの課題を深層学習を用いた経路計画することを検討する。深層学習による経路計画は事前に学習データを用いた学習が必要であるが、学習後には学習結果から高速に経路計画できる。また、RRTなどの乱数を用いた経路計画手法とは異なり、同一の始点終点に対して学習した結果を考慮した経路が計画できる。

そこで、本稿では敵対的生成ネットワークを用いて新たな経路計画手法を検討する。敵対的生成ネットワーク (Generative Adversarial Networks)<sup>3)</sup> とは 2014 年に Goodfellow らによって発表された新しい深層学習モデルである。敵対的生成ネットワークは深層学習において、「生成モデル」と呼ばれ、学習データに似た新しいデータを生成するモデルである。生成モデルには敵対的生成ネットワーク以外にも VAE(Variational Auto Encoder)<sup>4)</sup> がある。敵対的生成ネットワークは手動で学習データをラベリングする必要がなく、従来の深層学習と比べ、学習データの準備が容易になる。また学習データに似たデータをネットワーク自身でも生成し学習に用いるため学習データも少なくて済む。つまり、敵対的生成ネットワークを用いることにより、深層学習を利用する時に課題である「大量の学習データの準備」を解決する。また、提案手法では学習データ以外のデータにも対応する汎化能力が期待できる。

敵対的生成ネットワークは主に画像生成などの視覚ベースのタスクに用いられており、経路計画など移動ロボットの行動計画にはあまり用いられていない。本稿では移動ロボットの経路計画において敵対的生成ネットワークを適用し、得られた結果を評価および考察する。

### 2 敵対的生成ネットワーク

#### 2.1 敵対的生成ネットワークの理論

敵対的生成ネットワークは、2つのニューラルネットワークで構成される。1つ目のネットワークは、生成ネットワーク G であり、もう1つは識別ネットワーク D である。敵対的生成ネットワークの概要を Fig.1 に示す。生成ネットワーク G は  $x = G(z; \theta_g)$  のデータを直接生成する。識別ネットワーク D は学習データから得られるデータと、生成ネットワーク G から得られるデータとを識別する。また、識別ネットワーク D は、 $D(x; \theta_d)$  から与えられる確率を出力する。データ  $x$  が学習データからサンプリングされたものであれば確率  $p = D(x) \in [0, 1]$  を出力し、生成ネットワーク G からサンプリングされたものであれば確率  $1 - p$  を出力する。学習において最良の結果は、識別ネットワーク D が全入力に対し、0.5 の確率を出力し、生成ネットワーク G は学習データと同一の分布のデータを生成することである。

生成ネットワーク G と識別ネットワーク D の目的関数は

$$V(D, G) = E_{x \sim p_{data}(x)} [\log D(x)] + E_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (1)$$

であり、価値関数  $V(G, D)$  で表現されるゼロサムゲームとして定義する。 $p_z$  はノイズサンプル  $z$  を入力とした確率分布を表し、 $p_{data}$  は学習データを入力とした確率分布を表す。生成ネットワーク G は識別ネットワー




Fig. 1: Structure of Generative Adversarial Networks

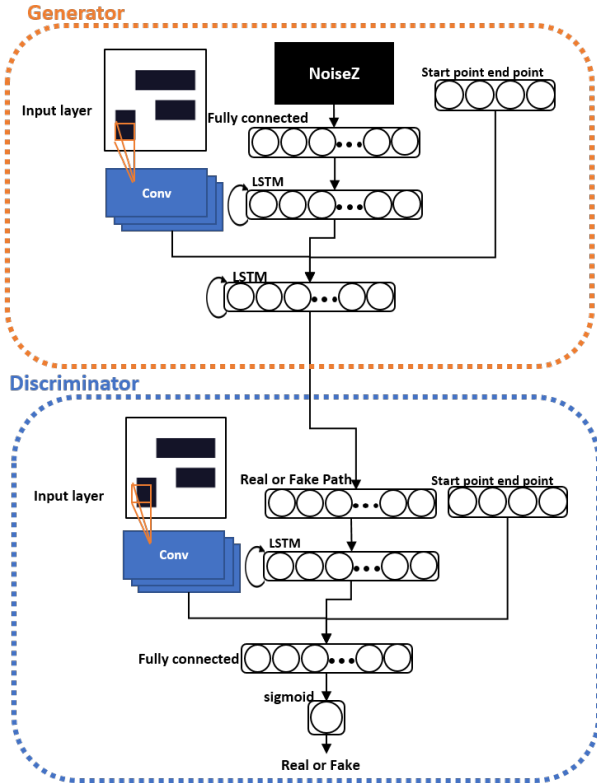


Fig. 2: Structure of the proposed method

ク D が学習データか生成ネットワーク G の生成したデータかどうかを間違えて識別するように目的関数を最小化する。識別ネットワーク D は目的関数を最大化し、学習データと生成ネットワーク G の生成したデータの識別境界を求める。このように生成ネットワーク G と識別ネットワーク D が敵対的に競争しながら最適化を行うことで学習データに近いデータを生成できるようになる。実際の学習では同時に学習はできないため、生成ネットワーク G と識別ネットワーク D を交互に学習を行う。具体的には、生成ネットワーク G の更新パラメータを固定し、識別ネットワーク D を最適化するステップと識別ネットワーク D の更新パラメータを固定し、生成ネットワーク G を最適化するよう更新するステップを交互に行うことで最適解を求める。

## 2.2 敵対的生成ネットワークモデルの内部構造

本稿で提案する経路生成のための敵対的生成ネットワークの生成ネットワーク G、識別ネットワーク D それぞれの内部構造を Fig.2 に示す。

識別ネットワーク D、生成ネットワーク G それぞれの環境地図入力は畳み込みニューラルネットワーク<sup>6)</sup>を用いて特徴量抽出を行う。畳み込み層の構成を表1のように構築する。畳み込み層では、初期値の依存性の解消・損失関数の勾配消失を防ぐため、BatchNormalization 処理<sup>8)</sup>を施し、過学習を防ぐ目的で、学習時にネットワークの自由度を強制的に小さくし汎化性能を上げる Dropout 処理<sup>9)</sup>を組み込んでいる。

生成ネットワークの出力層にはリカレントニューラルネットワーク (RNN) の 1 種である LSTM (Long short-term memory)<sup>7)</sup>を用いる。LSTM は、RNN の拡張として提案され、時系列データに有効であると考

Table 1: Map convolution input layer

Layer	Stride	Size	Func	Param
Input	-	100 × 100 × 1	-	
Conv	2	50 × 50 × 32	LReLU	320
Drop	-	50 × 50 × 32	-	0
Conv	2	25 × 25 × 64	LReLU	18k
Pad	-	26 × 26 × 64	-	0
BN	-	26 × 26 × 64	LReLU	256
Drop	-	26 × 26 × 64	-	0
Conv	2	13 × 13 × 128	LReLU	73k
BN	-	13 × 13 × 128	LReLU	512
Drop	-	13 × 13 × 128	-	0
Conv	1	13 × 13 × 256	LReLU	295k
BN	-	13 × 13 × 256	LReLU	1024
Drop	-	13 × 13 × 256	-	0

えられるモデルである。ここでは LSTM 層の隠れ層数は 32、活性化関数は  $\tanh$  (ハイパボリックタンジェント) である。

生成ネットワーク G は環境地図、正規分布にしたがって生成したノイズ  $z$ 、経路の始点終点を入力とし、経路を出力する。識別ネットワーク D は、学習データセット (RRT\*アルゴリズムで生成した経路) か生成ネットワーク G の計画した経路、環境地図、経路の始点終点を入力し、本物 (データセットサンプル) か偽物 (生成ネットワーク G サンプル) を識別し学習する。

## 3 提案手法による経路生成

### 3.1 学習データの作成

学習データとして、RRT アルゴリズムをベースとして生成経路が最適値に近づくよう改良された RRT\*アルゴリズムを用いる。障害物の存在する環境において、RRT\*アルゴリズムで生成された経路 (学習データとして適切な経路を選定) をそれぞれ 1000 通り生成し、これを敵対的生成ネットワークの学習データセットとする。また、経路の始点と終点は乱数により障害物に干渉しない点を選択する。

### 3.2 学習の流れ

作成した学習データを用いて生成ネットワーク G と識別ネットワーク D の学習を行う。

1. バッチ  $m$  個のノイズ  $z^{(1)} \dots z^{(m)}$  を生成する。
2. バッチ  $m$  個のサンプル  $x^{(1)} \dots x^{(m)}$  を学習データセットから選定する。
3. (環境地図, 始点終点, 経路) を入力とし、下記式を確率的勾配を上るように識別ネットワーク D を更新する。

$$\nabla_{\theta_d} \frac{1}{m} \sum_{i=1}^m [\log D(x^i) + \log (1 - D(G(z^i)))] \quad (2)$$

4. 上記までを  $k$  回繰り返す。(本稿では  $k = 1$  とする。)
5. バッチ  $m$  個のノイズ  $z^{(1)} \dots z^{(m)}$  を生成する。



6. 下記式を確率的勾配を下るように生成ネットワーク G を更新する.

$$\nabla_{\theta_g} \frac{1}{m} \sum_{i=1}^m \log(1 - D(G(z^{(i)}))) \quad (3)$$

7. すべての流れを学習回数分繰り返す.

### 3.3 新経路の生成

学習済みの生成ネットワーク G にテストデータを入力し, 経路を計画する. また, 経路にパススムージングを施し, それを評価用データとする.

## 4 シミュレーション

### 4.1 シミュレーション条件

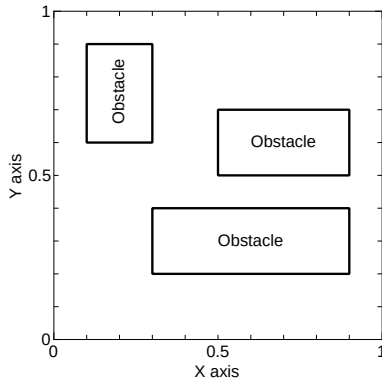


Fig. 3: Environment map

Fig.3 に示すような  $(x, y) = (0 \sim 1, 0 \sim 1)$  の範囲で障害物を含む環境地図を 10 種類用意し, この地図内に任意の始点, 終点を設定することで学習データの経路及び生成ネットワーク G の経路を生成する.

### 4.2 学習データセットの作成

学習データとして用いる経路の生成には RRT\* アルゴリズムを用いる. 経路の始点と終点は乱数により, 始点  $(x, y) = (0.0 \sim 0.2, 0.0 \sim 0.2)$ , 終点  $(x, y) = (0.8 \sim 1.0, 0.8 \sim 1.0)$  の範囲から各地図ごとに 1000 通り作成する. そして, それらの始点終点を入力として RRT\* アルゴリズムにより経路を各地図 1000 通り, 全 10000 通りの経路を計画し, これを学習データとして用いる. Fig.4 に各地図における RRT\* アルゴリズムを用いた経路計画の例を示す.

### 4.3 敵対的生成ネットワークモデルの学習

敵対的生成ネットワークの各パラメータについて表 2 に示す.

目的関数の Loss を Fig.5, 生成ネットワーク G が生成したサンプルに対して, 識別ネットワーク D の正解率を Fig.6 に示す. 識別ネットワーク D の正解率は学習終了間近では多くが 80% を超えており, 生成ネットワーク G が弱く, 識別ネットワーク D を騙せるサンプルを生成出来ていなかったことが分かる.

### 4.4 学習結果

学習後の生成ネットワーク G に, 各地図に 10000 通りの始点と終点を設定して経路計画し, 障害物に干渉している経路を失敗として正解率を求めた. 以下表 3 に結果, Fig.7 に生成ネットワーク G を用いた経路計画




Fig. 4: Paths generated by RRT\* algorithm

Table 2: Parameters of GenerativeAdversalNetwork Detail

Item	Detail
Map dimension	100 × 100 × 1
Path dimension	200 × 2
Start and goal point dimensions	1 × 4
Z noise dimension	100
Batch Size	200
Epoch	6000
Optimization function	RMSProp <sup>5)</sup>
Learning rate	0.00002
Initial bias	None

を示す. Map1 に関しては 10000 通りの経路に対して障害物を回避する経路計画ができた. しかし, 他の地図の場合では障害物を回避するよう経路計画できなかった. これは敵対的生成ネットワークで学習をする上で問題となっているどの出力もある特定のデータと同一のデータが出力されてしまうモード崩壊が起きているためだと考えられる. モード崩壊は, Fig.6 より, 識別ネットワーク D の正解率が学習終了付近 80 ~ 90% 程度に収まっていることから推測できる.

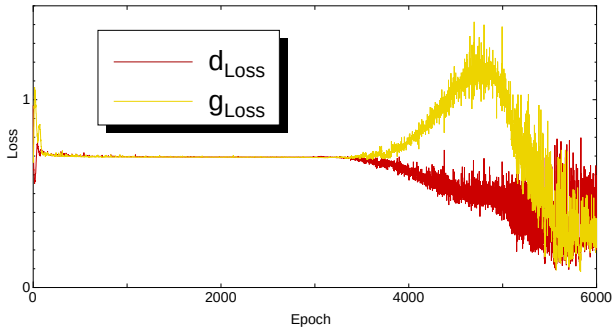


Fig. 5: Evaluation value of loss function




Fig. 6: Discriminator accuracy

## 5 おわりに

RRT\*アルゴリズムで経路計画したデータから学習し、敵対的生成ネットワークによる移動ロボットの移動経路を計画する手法を提案した。10種類の地図に対して任意の始点終点を与えると、生成ネットワークGは、ある特定の地図にのみ障害物回避経路を計画できることを確認した。

全地図に対して類似した経路が計画された原因として、モード崩壊が起きていること、生成ネットワークGより識別ネットワークDのほうが学習の進捗が早いため生成ネットワークGの学習が進まなかったことにあると考えられる。目的関数やネットワークのパラメータ、学習データ、学習回数について今後さらなる検討を行う必要がある。

## 参考文献

- 1) Steven M. Lavalle and James J. Kuffner and Jr. : Rapidly-Exploring Random Trees: Progress and Prospects, Algorithmic and Computational Robotics: New Directions,293/308 (2000)
- 2) Akira Nakayama and Tsutomu Anazawa : DIJKSTRA-BASED ALGORITHMS FOR THE SHORTEST PATH PROBLEM WITH EDGES OF NEGATIVE LENGTH, 日本オペレーションズ・リサーチ学会論文誌,56-2,137/154, (2013)
- 3) Goodfellow, Ian and Pouget-Abadie, Jean and Mirza, Mehdi and Xu, Bing and Warde-Farley, David and Ozair, Sherjil and Courville, Aaron and Bengio, Yoshua : Generative Adversarial Nets, Advances in Neural Information Processing Systems 27,2672/2680 (2014)
- 4) Kingma, Diederik P. and Welling, Max : Auto-Encoding Variational Bayes.,CoRR,abs/1312.6114 (2013)
- 5) Tieleman, T. and Hinton, G. : Lecture 6.5—RmsProp: Divide the gradient by a running average of its re-

Table 3: Accuracy of generated path[%]

Map1	Map2	Map3	Map4	Map5
100.0	0.0	0.0	0.0	0.0
Map6	Map7	Map8	Map9	Map10
0.0	0.0	0.0	0.0	0.0




Fig. 7: Paths generated by the generator

cent magnitude,COURSERA: Neural Networks for Machine Learning (2012)

- 6) Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner. : Gradient-based learning applied to document recognition, Proc. of the IEEE, pages 2278–2324, 1998.
- 7) Hochreiter, S. and Schmidhuber, J : Long Short-Term Memory, Neural Computation, Vol. 9, No. 8, pp.173/1780 (1997)
- 8) Ioffe, Sergey and Szegedy, Christian : Batch normalization: accelerating deep network training by reducing internal covariate shift, Proceedings of the 32Nd International Conference on International Conference on Machine Learning, Vol. 37 ,No.9, pp.448/456 (2015)
- 9) Srivastava, Nitish and Hinton, Geoffrey and Krizhevsky, Alex and Sutskever, Ilya and Salakhutdinov, Ruslan :Dropout: A Simple Way to Prevent Neural Networks from Overfitting,J. Mach. Learn. Res., Vol. 15, No. 1, pp.1929/1958 (2014)

# 対話ロボットの自然な“あいづち”に向けた研究

○野柳晴華, 大島千佳, 中山功一 (佐賀大学)

## Toward a Natural Nodding of an Interactive Robot

\* H. Yanagi, C. Oshima and K. Nakayama (Saga University)

**Abstract**— Generally, interactive robots have a time lag before the next utterance, because the robots need a little time to understand what a person who is a conversation partner talked. Since the person tries to take back the turn, he/she is apt to restart his/her utterance despite of overlapping with the robot's next utterance. Therefore, we think that the robots should nod in response before the utterance of the person ends. In this paper, we investigated which method is appropriate to make a learning model that estimates a timing of nod using information of volume and pitches in the utterance of the person. The result showed that Random Forest Classifier was an appropriate learning model method.

**Key Words:** Scikit-learn, Volume and pitch, Prosody

### 1. はじめに

認知症患者やお年寄りとは頻りに同じ会話を繰り返すが、人間にとって、同じ会話を繰り返し聞くことは負担である。そこで、ロボットが認知症患者やお年寄りの話し相手となれば、その家族や介護士の負担を軽減できる、という考えから、中山研究室では、CATAROという話し相手ロボットを開発している。しかし、この対話ロボットとの対話では、人間が話しかけてから、ロボットが応答するまでに、不自然なタイムラグがある。このタイムラグのあいだに、発話者はCATAROが応答しないと思い、再び話しかけてしまう。しかし、人間が再び話し始めるのとほぼ同時に、CATAROが応答を始めてしまい、話をさえぎられる形になってしまう。機械は、発話者の内容を音声認識によりすべて理解してからでなければ応答できない。そのため、音声認識に時間がかかる場合、スムーズに会話ができない、ということになる。また、発話の途中で相槌を打つような応答もできない。しかし、機械が人間の代わりとして話し相手になる場合、相槌を打つような応答は重要であると考えられる<sup>1)</sup>。そこで、本研究では、人間同士のコミュニケーションにおいては、発話内容が理解できていない状況でも自然に相槌が打てる点<sup>2)</sup>に着目し、発話者から取得した音量と音高のみを用いて、応答の一種である“自然なあいづち”が打てるかについて研究した結果を報告する。

### 2. 実験に使用するシステム

#### 2.1 全体構成

今回の実験に使用したシステムの全体像を以下に示す。まず、音声ファイルを用意し、その音声を指向性マイクで取得する。その音声のデータをASIOioというソフトウェアで解析するためにQUAD-CAPTUREというオーディオ・インタフェースを使用する。次に、ASIOioで、取得した音声データをフーリエ解析し、音量と音高を算出する。この音量と音高のデータを用いて、scikit-learnによって機械学習を行い、学習モデルを作成する。

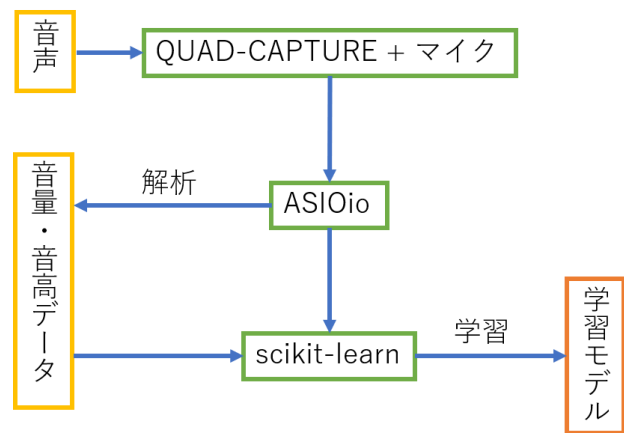


Fig.1: system model

#### 2.2 ASIOio

自然な相槌を実現するために、発話者の音量、音高を用いて機械学習を行い、学習モデルを作成する。この学習モデルに必要な音量と音高のデータを取得するために、ASIOioというソフトウェアの一部を改良し、用いた。これは、QUAD-CAPTUREの入力端子から入った音、あるいはソフトウェア上で読み込んだCSVファイルをリアルタイムで解析し、音量や音高などの音の情報取得できる。また、機械学習によって音声の感情情報を変化させることもできる。今回は、もともとの機能である音量と音高の解析部分とcsvファイルへの音量、音高の書き込み機能に加え、相槌ボタンを作成し、これを押し下げた瞬間の音量、音高のデータをファイルへ書き込むように改良した。これによって、相槌を打つとともにボタンを押すことで、人の自然な相槌のタイミングの音量と音高を取得する。また、音量と音高は1秒間に約200個のデータが取得できる。

#### 2.3 scikit-learn

機械学習部分においては、scikit-learnを用いる。これはPythonのオープンソース機械学習ライブラリである。様々な分類、回帰、クラスタリングアルゴリズムを備えている。今回は教師あり学習を行い、データは50個以上、うなずくか否かの2分類であったため、scikit-learn

公式ドキュメントにある scikit-learn algorithm cheat-sheet に従い、K Neighbors Classifier, さらに、Ensemble Classifiers 中の Random Forest Classifier を用いて学習モデルを作成した。scikit-learn algorithm cheat-sheet を fig.2 に示す。また、Random Forest Classifier に関してはグリッドサーチを用いてパラメータを調節する。




Fig.2: scikit-learn algorithm cheat-sheet<sup>3)</sup>

## 2.4 K Neighbors Classifier

K neighbors Classifier とは、特徴空間における最も近い学習例に基づいた分類の手法である。パターン認識や回帰分析によく用いられる。分類したいデータから最も近い k 個の学習用データの中で、最も多かったラベルを分類したいデータに割り当てる、という手法である<sup>4)</sup>。アルゴリズムは簡単だが、新たな点を分類したいときに時間がかかってしまうため、怠惰学習とも呼ばれる。scikit-learn ではパラメータとして Weights と n\_neighbors が設定できる。Weights には分類したいデータのラベル付けの際に、k 個のデータをどのように重み付けするかを設定でき、distance を設定すると k 個のデータとの距離的な近さによって重み付けをし、ラベルを判定する。uniform を設定すると均一の重みによって、つまり多数決によって分類したいデータのラベルを判定することになる。n\_neighbors は k の値を設定するパラメータである。このパラメータが小さすぎるとノイズに弱く、大きすぎると精度の低い学習モデルになってしまう<sup>5)</sup>。今回は、Weights に distance を、n\_neighbors には初期値である 5 を設定し、学習を行った。

## 2.5 Random Forest Classifier

Ensemble Classifiers とは、複数の学習器ので得た結果を組み合わせ、より高度な学習モデルを作る手法である<sup>6)</sup>。scikit-learn では、この Ensemble Classifiers の一つとして Random Forest Classifier がサポートされている。Random Forest Classifier は、決定木を複数用意して多数決によって分類を行う手法<sup>7)</sup>であり、分類や回帰、クラスタリングの問題の際に用いられる。単純な 2 分類を繰り返すことで決定木を構成するが、このとき、同じ決定木が構成されないようにブートストラップ・サンプリングという手法で、重複を許しながら学習用

データをとってきて決定木を構成する<sup>8)</sup>。今回、最も適切な決定木を構成するための、決定木の個数とデータの個数、およびノードの深さをグリッドサーチにより求めた。

## 2.6 グリッドサーチ

グリッドサーチとは、機械学習に用いるパラメータを自動的に最適化するための、scikit-learn の機能である<sup>9)</sup>。本研究では Random Forest Classifier においてグリッドサーチを行った。3つのパラメータ、n\_estimators と max\_depth, max\_features についてグリッドサーチを行った。n\_estimators は決定木の数を指定するためのパラメータであり、整数を指定する。max\_features は学習用データから一つの木を構成するために、いくつのデータを使用するかを設定するためのパラメータである。整数を指定すればその整数の分だけ、小数を指定すれば学習用データ全体のその割合だけ、データを用いて学習を行う。max\_depth は決定木の深さを指定するためのパラメータで、既定では None になっている。これを設定すると、過学習による精度の低下を避けることができる<sup>10)</sup>。

そのほかに、Random Forest Classifier のグリッドサーチにおいて設定したパラメータとして、random\_state と n\_jobs と class\_weight がある。random\_state と n\_jobs については、どちらも既定値を用いた。random\_state は、交差検証用に学習用データとテスト用データにサンプルデータを分ける場合などに用いる乱数のシード値で、既定値は 0 である。0 に設定するといつも同じデータに分割される。n\_jobs は並列計算を行うコアの数を指定するパラメータである。今回は -1 に設定した。-1 に設定すると最適なコア数を自動で判断して計算を行う。class\_weight は使用するデータのラベルごとの数が不均衡であった場合、その偏りを調節するためのパラメータである。設定できるのは None と balanced の 2 種類で、None は偏りを考慮しない場合に用いる。つまり、学習用データにラベル 1 とラベル 0 のデータが同じ数だけ含まれている場合に用いる。そうでない場合は balanced を設定する。balanced を設定すると、自動で重みづけの値を調整してくれる。今回、class\_weight にはすべて balanced を設定した。

## 3. 実験に使用するデータ

実験に使用する学習用データとして、音声ファイルの最初から最後まで音量と音高のデータと、相槌ボタンが押されるたびに記録される 800 個 1 セットの音量、音高のデータを用いた。約 10 分の男性のラジオ音声再生し、その音量と音高を QUAD-CAPTURE につなげたマイクから取得した。また、相槌のタイミングは人それぞれであることから、一人の人間の相槌を再現する方が、モデルの精度が上昇すると考え、被験者 9 人の相槌判定機のモデルをそれぞれ作成した。被験者はラジオ音声を聞きながら、相槌を打つ瞬間に、ASIOio の相槌ボタンを押す。1 回の相槌につき、400 個 (2 秒間) のデータを 400 個前 (約 2 秒前) から 600 個前 (約 3 秒前) まで 1 つずつずらし、音量、音高それぞれ 400 個、全 800 個のデータを 1 セットとし、200



セット用意した. さらに, これに 0 のラベルを付けた. また, 相槌を打っていない瞬間のデータとして, 相槌を打った瞬間とその前後 200 個のデータを使用するのを避け, 音声ファイルの最初から最後まで音量と音高のデータの先頭から末尾の 400 個手前まで, それぞれ 400 個, 全 800 個で 1 セットのデータを用意し, これに 1 のラベルを付けた. これらのデータセットを用いて 2 種類の機械学習を行い, 学習モデルを作成した. 相槌の瞬間を 0 として作成した, 学習用に編集したデータの範囲を Fig.3 に示す.

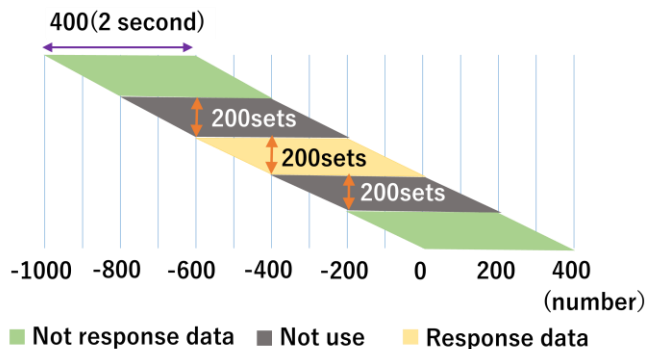


Fig.3: way of extract data

## 4. 実験

### 4.1 実験の目的

scikit-learn を用いて, K Neighbors Classifier, Random Forest Classifier の 2 種類の機械学習を行い, 音量や音高から相槌を打つタイミングを機械が判断できるのかを調べる. また, 音量や音高から相槌を打つタイミングが判断できる場合, どちらの分類方法がより適しているかを判断する. 判断する基準は正解率, 適合率, 再現率, F 値を用いる. Random Forest Classifier に関しては, 調節できるパラメータに対してグリッドサーチを行って算出された, 最も良い正解率, 適合率, 再現率, F 値を用いる. 適合率とは, 例えばクラス 0 だと学習モデルが判定したもののうち, 実際にクラス 0 であったものの割合を示す. 再現率とは, 実際にクラス 0 であるデータの中で, どれだけのデータが正しくクラス 0 だと判定されたかを示す. また, 正解率を出す方法として, k 分割交差検証を用いている. k の値はすべて 10 で行った. 再現率, 適合率, F 値はデータを学習用データとテスト用データに 9:1 に分割し, 算出した.

### 4.2 K Neighbors Classifier で学習モデルを作成

9 人の被験者のデータを用いて K Neighbors Classifier で機械学習を行った. Weights には distance を設定し, n\_neighbors は 5 に設定した. 10 回の交差検証を行った結果の適合率, 再現率, F 値, 正解率を被験者別に Table 1 に示す. 正解率では, 大きくばらつきがあり, その差は最大で 0.37 である. 正解率だけ見れば, 被験者 S3 の相槌を機械で再現するには K Neighbors Classifier は有効なように見えるが, 被験者 S3 のラベル 0 の再現率を見ると, 0.19 ととても低くなっている. また,

今回ラベルが 2 種類しかないことを考えると, 適合率や再現率が 60% を切っているものは低い数値であるといえる. どの被験者でもラベル 1 の適合率はおおむね高いが, ラベル 0 の再現率は低くなってしまいう傾向にある.

Table 1: The result of the learning models

(K Neighbors Classifier).

		K Neighbors Classifier			
		precision	recall	F-score	accuracy
S1	0	0.59	0.55	0.57	0.69
	1	0.74	0.77	0.76	
S2	0	0.37	0.67	0.47	0.60
	1	0.82	0.57	0.67	
S3	0	0.80	0.19	0.31	0.97
	1	0.98	1.00	0.99	
S4	0	0.95	0.65	0.77	0.84
	1	0.79	0.98	0.87	
S5	0	0.26	0.51	0.34	0.66
	1	0.87	0.69	0.77	
S6	0	0.96	0.24	0.38	0.91
	1	0.91	1.00	0.95	
S7	0	0.18	0.54	0.27	0.75
	1	0.95	0.77	0.85	
S8	0	0.88	0.43	0.43	0.90
	1	0.90	0.99	0.94	
S9	0	0.97	0.31	0.46	0.97
	1	0.96	1.00	0.98	

### 4.3 Random Forest Classifier でモデルを作成

9 人の被験者のデータを用いて Random Forest Classifier で機械学習を行った. グリッドサーチを行ったパラメータは n\_estimators, max\_features, max\_depth の 3 つである. n\_estimators は 5, 10, 20, 30, 50, 100, 300 を設定し, max\_features は 3, 5, 10, 15, 20, max\_depth では 3, 5, 10, 15, 20, 25, 30, 40, 50, 100 を設定して行った. 10 回の交差検証を行った結果の適合率, 再現率, F 値を被験者別に Table 2 に示す. また, グリッドサーチをしたの 3 つのパラメータ n\_estimators, max\_features, max\_depth をの被験者別の結果を Table 3 に示す. 正解率に関して, 被験者 S9 を除くすべての被験者が 90% を超えており, 正解率だけ見れば K Neighbors Classifier 制度の高い学習モデルであるといえる. 再現率, 適合率, F 値について, 被験者 S3 のラベル 0 における再現率が 0.52 と低いことと, 被験者 S9 のラベル 0 の適合率, 再現率が極端に低いことを除けば, おおむね高い数値が出ているといえる.

Table 2: The result of the learning models

(Random Forest Classifier)

		Random Forest Classifier			
		precision	recall	F-score	accuracy
S1	0	0.95	0.93	0.90	0.97
	1	0.94	0.97	0.96	
S2	0	0.96	0.88	0.92	0.96
	1	0.96	0.99	0.97	
S3	0	0.80	0.52	0.63	0.98
	1	0.99	1.00	0.99	
S4	0	0.96	0.97	0.96	0.97
	1	0.97	0.97	0.97	
S5	0	0.85	0.87	0.86	0.95
	1	0.97	0.97	0.97	
S6	0	0.88	0.80	0.84	0.97
	1	0.98	0.99	0.98	
S7	0	0.89	0.76	0.82	0.97
	1	0.98	0.99	0.98	
S8	0	0.79	0.79	0.79	0.94
	1	0.97	0.97	0.97	
S9	0	0.20	0.02	0.04	0.81
	1	0.83	0.98	0.90	

Table 3:Parameter of the learning models

(Random Forest Classifier)

Random Forest Classifier			
	n_estimators	max_features	max_depth
S1	300	20	15
S2	300	20	20
S3	300	20	15
S4	300	20	40
S5	300	20	15
S6	300	20	15
S7	100	15	15
S8	300	20	20
S9	300	5	20

#### 4.4 考察

実験結果から、人が相槌を打つ瞬間の発話者の音量や音高の変化から、一部を除く多くの被験者に対して、相槌を打つタイミングが機械で判定できることがわかった。ただし、被験者 S9 の結果から、すべての人間の相槌を再現することは難しい可能性がうかがえる。意見者 I の実験結果の詳細については、引き続き分析する予定である。

分類の手法としては、正解率や再現率、適合率、F 値のいずれかを考慮しても Random Forest Classifier のほ

うが精度の高い学習モデルが作れることが分かった。この理由についても、引き続き分析する。

#### 5. おわりに

本稿では、認知症患者のように同じ会話を繰り返す対象者の話し相手として、自然な相槌が打てるロボットの作成に向けて、対象者の会話に自然なタイミングで相槌ができるアルゴリズムの構築を目指した。実験結果から、多くの被験者に対して、音量と音高のみの情報から、適切なタイミングで相槌が打てる事を示した。本稿で提案したアルゴリズムであれば、会話の内容を理解する必要なく相槌ができる。このため、方言のきつい高齢者との会話や、発音の悪い高齢者との会話など、音声認識の難しい会話に対しても適用できる可能性がある。また、日本語という使用言語に限らずに、利用できる可能性もある。これらの点は、今後の課題である。

本稿で提案したアルゴリズムと実験結果から、実際に相槌を打つ 1 秒前までの音高と音量のデータを用いて、相槌を打てる可能性が示された。このため、相槌を打つ最大 1 秒前から相槌のうなずき動作をしつつ、1 秒以内に相手の発話を妨げないタイミングを見計らって相槌を打つなど、より自然な相槌を実現できる可能性があるかと筆者らは考えている。

今回、学習器の作成に K Neighbors Classifier や Ensemble Classifiers の Random Forest Classifier 以外の学習手法を用いなかった。今後はこれらの学習方法でも学習モデルを作成し、今回の結果と比較する必要がある。また、データの区切り方に関しても、今回は 2 秒ごとに 1 セットとしたが、1 秒や 0.5 秒に区切ったときに学習モデルの精度はどうなるのかを比較してみる必要がある。これらも、今後の課題である。

#### 参考文献

- 1) Young Hocho : 談話における相づちの運用と機能, 東北大学文学部日本語学科論集, 4 巻, 63/74 (1994)
- 2) 塚原千賀子 : あいづちの研究, 昭和女子大学大学院日本語教育研究紀要, 1 巻 1/10 (2001)
- 3) Choosing the right estimator  
[https://scikit-learn.org/stable/tutorial/machine\\_learning\\_map/](https://scikit-learn.org/stable/tutorial/machine_learning_map/) 2018/12/13 閲覧
- 4) K 近傍法(クラス分類) (KNeighbors Classifier) 【Python と scikit-learn で機械学習 : 第 4 回】  
<http://neuro-educator.com/ml4/> 2018/11/29 閲覧、最終更新日 2017/9/23
- 5) 機械学習 ~ K-近傍法 ~  
<https://qiita.com/fujin/items/128ed7188f7e7df74f2c> 2018/11/29 閲覧、最終更新日 2018/4/23
- 6) Python3 による日本語言語処理 (5)VotingClassifier による異なるモデルのアンサンブル学習  
<https://qiita.com/asai0304/items/6f7019b0e174d6628982> 2018/11/30 閲覧、最終更新日 2017/2/24
- 7) ランダムフォレスト  
<https://ja.wikipedia.org/wiki/ランダムフォレスト>

- 8) ランダムフォレスト(クラス分類) Ensemble Classification  
【Python と scikit-learn で機械学習：第 6 回】  
<http://neuro-educator.com/ml6/>  
2018/11/30 閲覧、最終更新日 2017/9/23
- 9) Scikit learn より グリッドサーチによるパラメータ最適化  
<https://qiita.com/yhyhyhj/items/c81f7cea72a44a7bfd3a>  
2018/11/30 閲覧、最終更新日 2016/5/8
- 10) Scikit-learn によるランダムフォレスト  
[https://data-science.gr.jp/implementation/iml\\_sklearn\\_random\\_forest.html](https://data-science.gr.jp/implementation/iml_sklearn_random_forest.html)  
2018/11/30 閲覧

# Projection-based ビジュアルサーボ法を用いた 複数対象物中指定対象物の実時間認識

○寇 ギョウ郡 田 宏志 李 想 戸田 雄一郎  
松野 隆幸 見浪 護 (岡山大学)

## Real-time Recognition of Specified Objects in Multiple Objects by Projection-based Visual Servoing Method

\*Y. Kou H. Tian X. Li Y. Toda T. Matsuno and M. Minami (Okayama University)

**Abstract**— The visual servoing has been introduced as an approach to expand the application of the robot and make the robot to work automatically. Mainly, the visual servoing approach aims to control the motion of the robot (dynamic system) through vision information that obtained from the stereo vision system. Therefore, the process of processing the vision information should be as quick as possible in real-time estimation, especially in an unknown environment, the recognition process needs to be quick enough to adapt to the changing background and multiple unknown target object. Although many studies have been conducted, the researchers are still facing the problems to realize the recognition of arbitrary objects and switch target object in real-time. In this paper, we propose an approach named “projection-based” method to solve the problem. Among various advantages, the projection-based method does not need preset models of target objects and taking advantage of the way to establish the model in real-time, the projection-based method can avoid the correspondence, these features ensured high robustness towards the environment. In this paper, the experiments towards the specified target object amid multiple objects can demonstrate the efficiency of the projection-based method.

**Key Words:** Visual servoing, Projection-based method, 3D pose real-time estimation, Multi objects

## 1 Introduction

Visual servoing has been introduced as an approach to expand the application of robots to realize the automatic works. The aim of visual servoing approach is to control the motion of robot (dynamic system) through vision information that obtained from the vision system. To the visual servoing systems, they can be generally classified by the number of cameras, cameras' position with respect to the robot, and the plan to minimize the error to control the robot. Until now, the classic approach to achieve visual servoing can be classified by their control law [1] into: 1) position-based visual servoing, 2) image-based visual servoing [2], 3) 2.5D visual servoing [3].

To the way to realize the visual servoing, there have been many studies proposed and submitted due to its importance. However, the main problem of visual control law is still remained: the definition of the target object or the establishment of a model of a target. Normally, the classic approach of visual servoing methods define the model in advance, this way can simplify the difficulty of recognition process and reduce the burden on the system, but it increased the hardness of the detection of objects that not included in the database of models, for more serious cases, the visual servoing may fail in sudden. Meanwhile, the correspondence problem [4], [5] is seen as a big problem may lead the servoing to failure. Due to the established model contained the size, features, shape information of target object, and the main way to realize the detection is to compare the features of model and image of the target object shown in cam-

era, this problem will occur when the known features are missed, such as the target object changed its pose, as well as the vision field of the camera, is changed.

To this facts, the projection-based method is proposed to overcome the drawbacks. Comparing with other approaches, the projected-based method mainly has the following advantages: firstly, the prior-knowledge is inessential, the model can be changed in real time to achieve the recognition of the arbitrary object. Also, in the projection-based method, the model is established as the point cloud, each point in the model carried the color information of target object, no matter how the target changes its pose, the color won't change, this form of the model can avoid the correspondence problem to some content.

Based on the projection-based method, the robots can perform automatic work in extreme environments such as deep sea and disaster relief site due to its feature.

## 2 Methodology

### 2.1 Projection-based Method

The main drawback of the visual servoing methods talked above is that the solution of the corresponding points problem. Furthermore, one or multiple preset models are needed to compute the pose of a target, which may lead to a low flexibility to the whole system though it can achieve a high accuracy of recognition. The human can distinguish the distance of objects in 3D space through parallax, that is an advantage of the stereo vision, by this kind of feature, the human has the sense of distance with the aid of stereopsis.



Aroused by the fact introduced above, we proposed a method that uses image information obtained directly from the camera, to satisfied the solution of the above problems. The details of the projection-based method will be introduced below.

## 2.2 The advantages of projection-based method

Talked about the visual servoing, the main application towards the robot is to control the robot to achieve several operations automatically. However, when the recognition was operated in a changing environment or the target object is unknown, it is hard to determine different objects with a single given model. To this situation, the method that could estimate the arbitrary object is considered important. For the methods described above, the searching model was made in advance, to switch model in real time is a difficult task, to realize this function, the projection-based method is aimed to create the changeable searching model to satisfy the different target object in real time. Meanwhile, due to the model was consisted by points cloud, the correspondence problem can be solved to some content, for this fact, the projection-based visual servoing system can be seen as having a high robustness.

## 2.3 Configuration of the System

In this system, to control the robot with an estimated result, a dual-eye cameras configuration is used. Two cameras were set in the end-effector of the manipulator, formed the hand-in-eye configuration. Meanwhile, to support the real-time on-line visual servoing, the speed of recognition is strictly demanded. Here, we choose the real-time multi-step ga as the best solution, to a raw image, the rt-ms ga could evolve generations during 33[ms]. To this fact, we use 2 PCs to operate the recognition process individually to ensure the computing speed. The process of processing the image information will be introduced in the next subsection. Meanwhile, to control the target object's moving, a robot to hold the target object is also set individually.

## 2.4 Generation of Desired-Trajectory

Fig. 1 shows the relationship between the hand and the object.  $\Sigma_W$  is the world coordinate system, and  $\Sigma_M$  is the coordinate system fixed on the object. Furthermore, the coordinate system of the actual hand and its target coordinate system are represented by  $\Sigma_E$ ,  $\Sigma_{Ed}$ . The relative position/orientation relationship between the target state of the hand and the object is represented by the homogeneous transformation matrix  ${}^{Ed}T_M$ . And the relationship between the actual hand and the object is represented by  ${}^E T_M$ . At this time, the difference between  $\Sigma_E$  and  $\Sigma_{Ed}$  is expressed as  ${}^E T_{Ed}$ . And  ${}^E T_{Ed}$  can be described as follows.




Fig. 1: Motion of the end-effector and object

$${}^E T_{Ed}(t) = {}^E T_M(t) {}^{Ed} T_M^{-1}(t) \quad (1)$$

(1) includes an arbitrary motion  ${}^E T_M(t)$  of the object represented by  $\Sigma_E$  and the relative time-varying visual servo target trajectory  ${}^{Ed} T_M(t)$  represented by the arbitrary target position/orientation of the robot hand  $\Sigma_{Ed}$ .  ${}^E T_M(t)$  is measured by online model based recognition method combined with a recognition method [6] that uses the velocity/angular velocity information of the hand as feedforward information and a moving image recognition method RT-MS GA [7], to recognize moving image sequence input at video rate. When the estimated object is represented by  $\Sigma_{\hat{M}}$ , it is general that an error  ${}^M T_{\hat{M}}$  exists between the actual object  $\Sigma_M$  and the detected object  $\Sigma_{\hat{M}}$ . Here, we reconstruct the position/orientation error  ${}^E T_{Ed}(t)$  of the hand represented by (1) based on the object  $\Sigma_{\hat{M}}$  estimated as follows.

$${}^E T_{Ed}(t) = {}^E T_{\hat{M}}(t) {}^{\hat{M}} T_{Ed}(t) \quad (2)$$

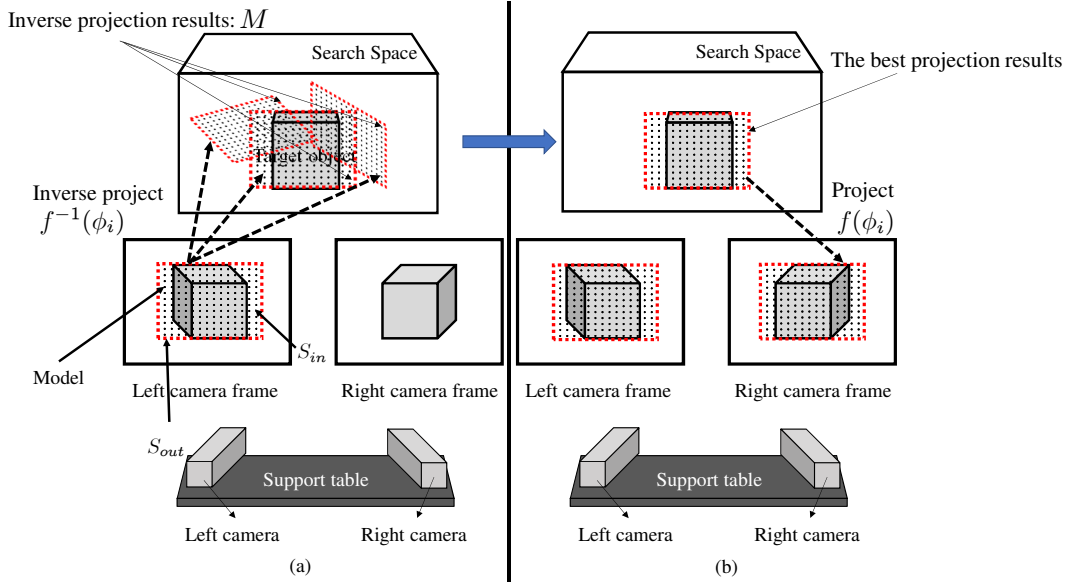
When (2) is differentiated with respect to time, the following equation is obtained.

$${}^E \dot{T}_{Ed}(t) = {}^E \dot{T}_{\hat{M}}(t) {}^{\hat{M}} T_{Ed}(t) + {}^E T_{\hat{M}}(t) {}^{\hat{M}} \dot{T}_{Ed}(t). \quad (3)$$

Here,  ${}^{\hat{M}} T_{Ed}$ ,  ${}^{\hat{M}} \dot{T}_{Ed}$  is given in advance as the target trajectory of the visual serving, and  ${}^E T_{\hat{M}}$ ,  ${}^E \dot{T}_{\hat{M}}$  is observed by multi-step GA.  ${}^E T_{Ed}(t)$  and  ${}^E \dot{T}_{Ed}(t)$  are the position/orientation error between  $\Sigma_E$  and  $\Sigma_{Ed}$  and its time differentiation, which is necessary when constructing the controller. As shown in Fig. 1, there are two errors that should be 0 in the visual servo process. One is the recognition error between the actual object and the detected object  ${}^M T_{\hat{M}}$ , and the other is the error of the motion control given by the target state of the hand and the actual hand  ${}^E T_{Ed}$ .

## 2.5 Projection and Inverse Projection

As same as the humans' eyes, the configuration of dual-eye cameras can focus the sight on one target. For this reason, the parallax error could give the stereoscopic effect, which enables human to detect the



$\phi_i$ : Pose estimation by ga       $f^{-1}(\phi_i)$ : inverse projection  
 $f(\phi)$ : projection

Fig. 2: The process of projection-based method

distance roughly. On the basis of this feature, the main goal of the projection-based method is to evaluate the recognition result by parallax error from the left and right image.

Shown in Fig.2, firstly, 1) two cameras were set on the top of support table and formed a dual-eye cameras configuration, the support table is a metal slab to ensure the two cameras be held in the same horizon line, 2) then the target object's images are projected into the left and right cameras' lens naturally. 3) For no preset model, the model to detect the pose is only created by the center part of the left image, after the model is established, we inverse project the model into 3D search space by assuming the pose  $\phi$  of the target object with RT-MS GA. Here, the assumed pose included the position and orientation  $\phi = [x, y, z, \varepsilon_1, \varepsilon_2]$ . The 3D search space is a part of the real world that in front of the camera, we defined the 3D search space as a limited space where we only inverse project the model into the inside of the 3D search space. 4) After the inverse projection is completed, we project the model into the right camera's lens again. Though the pose of the right camera has already known, the image information of a natural projected image of the target object in right camera and the projected image of the model in right camera should all be obtained. By analyzing the similarity between the re-projected result and natural image, we can evaluate the recognition result of this time. In the fig.4, the  $f_L(\phi)$  and  $f_R(\phi)$  mean the natural projection of target object, the position of natural image of the target object can be given as:

$$f_L(\phi) = \mathbf{P} \cdot {}^{CL}\mathbf{T}_M(\phi) \cdot {}^M\mathbf{r} \quad (4)$$

$$f_R(\phi) = \mathbf{P} \cdot {}^{CR}\mathbf{T}_M(\phi) \cdot {}^M\mathbf{r} \quad (5)$$

In the Eq.4,5, the " $\phi$ " means the true pose of target object in the 3D searching space. Meanwhile, the  $\mathbf{P}$  is the projection transformation matrix.

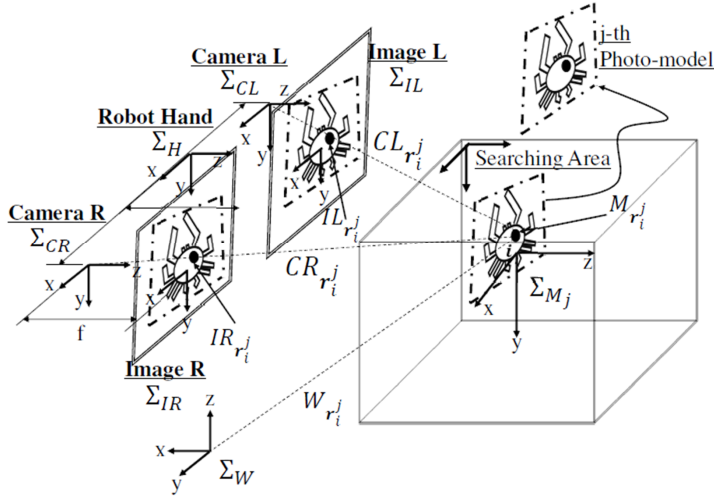
Then, after recording the distribution of hue value of the model, the RT-MS ga begins to search the model's position in the left camera image, at that time, the model is a 2D plane image only has the information about  $x, y$  axis in the coordinate of left camera's image  $\Sigma_{LL}$ . After the RT-MS ga confirmed the position of model  ${}^{LL}\mathbf{r}$ , shown as Fig.9 and 10, the  $f_L^{-1}$  means the inverse-projection.

We all know that the projection is a transformation from 3D into 2D, therefore the inverse-projection is a transformation of 2D to 3D. In fig.9, the inverse-projection  $F_L^{-1}$  can be given as:

$$f_L^{-1}(\phi_i) = {}^M\mathbf{T}_{CL} \cdot \mathbf{P}^+ \cdot {}^{LL}\mathbf{r} \quad (6)$$

In eq.6, the  $\mathbf{P}^+$  is the inverse projection transformation matrix, and the  $\phi_i$  means the assumed target object's pose by RT-MS ga, and it can be expanded as  $\phi_i = [x_i, y_i, z_i, \varepsilon_{1i}, \varepsilon_{2i}]$ , as introduced above, we can see if the  $\phi_i$  is completely equal to  $\phi$ , the RT-MS ga assumed value can be seen correctly. For evaluating the inverse-projection result, we re-project the inverse projected model into right camera image, by evaluating the overlap degree of re-projected result  $f_R(\phi_i)$  and the natural image  $f_R(\phi)$ , we can evaluate the recognition result. Here, the re-projection equation of the situation in fig.9 can be given as:

$$f_R(\phi_i) = \mathbf{P} \cdot {}^{CR}\mathbf{T}_M(\phi_i) \cdot {}^M\mathbf{r} \quad (7)$$



- $W_{r_i}^j$ : position of an arbitrary j-th point on i-th 3D model based on  $\Sigma_W$
- $M_{r_i}^j$ : position of an arbitrary j-th point on i-th 3D model in  $\Sigma_M$ , where  $M_{r_i}^j$  is a constant vector
- $CR_{r_i}^j$  and  $CL_{r_i}^j$ : position of an arbitrary j-th point on i-th 3D model based on  $\Sigma_{CL}$  and  $\Sigma_{CR}$
- $IR_{r_i}^j$  and  $IL_{r_i}^j$ : projected position on  $\Sigma_{IL}$  and  $\Sigma_{IR}$  of an arbitrary j-th point on i-th 3D model

Fig. 3: The coordinate relationship between the cameras, hand, and target object

Here, in eq.7, the  $\phi_i$  is the pose assumed by RT-MS ga of the target object, and the  $M_{r_i}$  is the position of arbitrary points of a model in model coordinate  $\Sigma_M$ .

The result can be expected is shown in Fig.4. Here,  $f_L^{-1}$  is the process of inverse projection. In Fig.4(a) and Fig.4(b), the pose that rt-ms ga is different. In Fig.4(a), the pose is given as  $\phi_i = [x_i, y_i, z_i, \varepsilon_{1_i}, \varepsilon_{2_i}]$ , due to there is a error between the inverse projected result and true pose of the target object, the recognition result reflected in the fitness is lower than the Fig.4(b) because in Fig.4(b), the inverse projected result is completely overlapped with the true pose of target object. To Fig.4(c), if the  $\phi$  gives the highest peak in  $F(\phi)$  distribution (fitness value distribution), a problem to find the 3D pose of 3D target projected in left and right camera could be converted into optimization problem, find  $\phi$  to maximize  $F(\phi)$  in parameter space of  $\phi = [x, y, z, \varepsilon_1, \varepsilon_2]$  in 3D space.

## 2.6 Evaluation Method

After the model created in the left image and the searching model re-projected into the right image, we use the fitness function to evaluate the recognition result. The fitness function is constructed to calculate how much degree that the projected model defined by its pose  $\phi$  matches with the captured image. Mainly, the fitness function can be given by the following equation:

$$F_R(\phi) = \left\{ \sum_{IR_{r_i} \in S_{R,in}(\phi)} p(IR_{r_i}) + \sum_{IR_{r_i} \in S_{R,out}(\phi)} p(IR_{r_i}) \right\} / (2 \times N_{R,in} + 0.1 \times N_{R,out}) \quad (8)$$

If the projected 2D model completely coincides with the captured target object in the left and right im-

ages, the fitness value that calculated by fitness function is designed to have a maximum value. Therefore, the fitness value distribution for all models will be shaped with a peak that represented the real pose of the target object. The concept of the fitness function in this method can be said as an extension of the work in [10] in which different models including a rectangular shape surface-strips model were evaluated using images from a single camera.

Since evaluation functions for left and right cameras are the same and total fitness function is average of them, let us explain the contents of Eq.(8) here only in the case of left camera. The evaluation of every points in the input image that lie inside the surface model frame and outside area of the model frame are represented as  $IL_{r_i} \in S_{L,in}(\phi)$  and  $IL_{r_i} \in S_{L,out}(\phi)$  respectively.  $p_{L,in}(IL_{r_i})$  and  $p_{L,out}(IL_{r_i})$  are calculated by following equation:

$$P_{L,in}(IL_{r_i}) = \begin{cases} 2, & \text{if } (|H_M(IL_{r_i}) - H_I(IL_{r_i})| \leq 20) \\ -1, & \text{if } (|H_M(IL_{r_i}) - H_I(IL_{r_i})| > 20) \end{cases} \quad (9)$$

$$P_{L,out}(IL_{r_i}) = \begin{cases} 0.1, & \text{if } (|H_M(IL_{r_i}) - H_I(IL_{r_i})| \leq 20) \\ -2, & \text{if } (|H_M(IL_{r_i}) - H_I(IL_{r_i})| > 20) \end{cases} \quad (10)$$

where  $S_{L,in}$  is the space of coordinates on the surface area of the model,  $S_{L,out}$  is the space of coordinates on the outside area of the model,  $H_M(IL_{r_i})$  is the hue value of the 2D model at the point  $i$ -th in the  $S_{L,in}$  and the  $H_I(IL_{r_i})$  is the hue value of the captured image at the  $i$ -th point. This kind of fitness function has a high robustness towards illumination variation. Eqs.(9) and (10) are designed to provide a peak in fitness value distribution by reducing noises. The evaluation values are tuned experimentally.


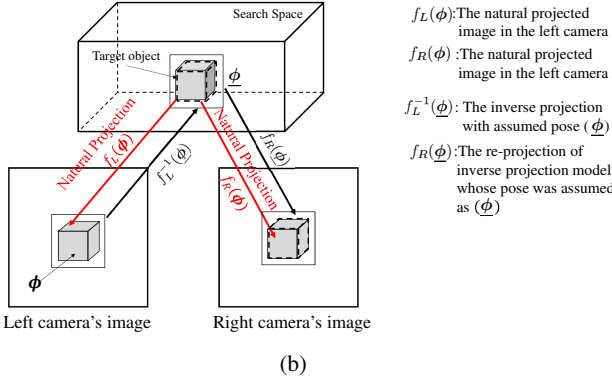



Fig. 4: The recognition result based on different projected model. (a) there is a error between the inverse projected result and the true position of target. (b) the inverse projected result is completely overlapped with the target object. (c) the detection reflected in the fitness value

Here, detailed explanation on Eqs.(9) and (10) is presented.

In Eq.(9), if the hue value of each point of captured images, which lies inside the surface model frame  $S_{L,in}$ , is similar to the hue value of each point in a model, i.e., the difference be less than 20, the fitness value will increase with the voting value of “+2.” The fitness value will decrease with the value of “-1” for




Fig. 5: Gene information

every point of target in the left camera image that is similar to the value of the background. Similarly, in Eq.(10), if the hue value of each point in the left camera image, which is in  $S_{L,out}$ , is the same to the hue value of background with the tolerance of 30, the fitness value will increase with the value of “0.1.” Otherwise, the fitness value will be decreased with the value of “-2.” The detailed explanation of fitness function is discussed in [9] and [10].

## 2.7 Genetic Algorithm(RT-MS GA)

By using a fitness function, the problem that searching for the pose  $\phi$  of an object can be transposed to the problem that searches for the maximum of a fitness function  $F(\phi)$ . In this research, we use GA to get the maximum fitness value in the consecutive input dynamic image sequences by video rate. The gene information showing the position/orientation on the individual in this research is shown in Fig.5. The position/orientation of the individual gene shows the pose of the solid model in the model-based matching method. Top 24 bits with every 10 bits of this gene express the position coordinate of a solid model, and remainder 24 bits with every 14 bits expresses the orientation of the solid model, where the orientation is defined by the quaternion. Less bit number assigned for position and orientation of genes, requires the less evolving time of RM-GA, enabling the repeating time in one video input period, 33[ms] increase. However the rough in bit member assigned of pose induces incorrect estimation. Therefore the bit assigned length and the performance of RM-GA conflict each other. The length of a gene has been determined empirically.

Next, each individual gene gets a fitness value from the fitness function  $F(\phi)$  using its assumed pose information  $\phi$ . Evolution processing is performed based on the superiority or inferiority of this value, and a set of possible solutions of pose  $\phi$  for the next generation is modified through GA’s process. At this time, the pose whose fitness value was high in the former generation, that is, it approaches toward the maximum neighborhood of the fitness function that represents the target object. By repeating this process (change of generation), GA discovers the maximum value showing the true pose of the target object. However, normal GA needs to wait for convergence for a definite period of time. When a fitness function shows a value high enough and estimation of object is judged to be completed that means matching with the solid model into the target has been done, the GA is thought that it has found the best result to present the pose. Since usually, a time has passed before the GA’s conver-



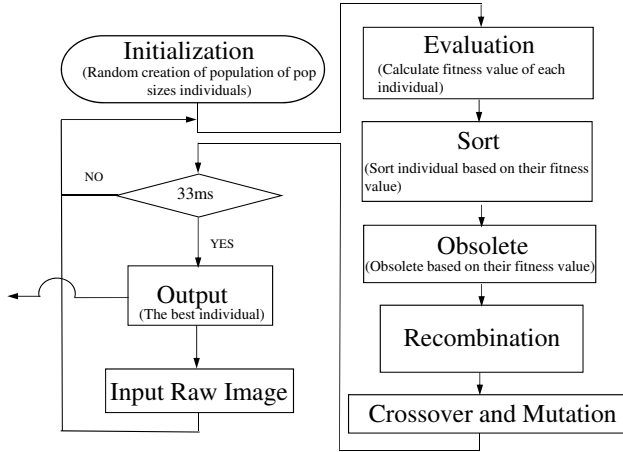


Fig. 6: Real-time multi-step GA




Fig. 7: The 3 different target objects in the experiment

gence, there is a possibility that the surrounding situation may be changed a lot, that means the target object may have turned into a very different pose. Therefore we use RM-GA (Fig. 6). RM-GA is on-line estimation method [8]. Its evolving speed to optimize the fitness function should be faster than the target object's moving speed, then we can obtain the best gene at each time point of video rate. And by using the best gene, the recognition of the target's position and orientation can be realized online.

Utilizing RM-GA with reasonable performance in one loop and increasing accuracy with repeatable ability within real-time video rate is our approach strategy comparing to others that may provide powerful accuracy but also with the computational burden and time-consuming [11].

### 3 Experiment

To the feature that the projection can detect different target objects without the preset model, in this experiment, we prepared 3 different sea creatures to conduct an experiment to examine the recognition accuracy. The 3 different target objects are shown in Fig.7. All of these models are the plastic model of sea creatures, for this reason, the size may have a big error to the real one.

#### 3.1 Experiment Environment

Figure 8 shows the experimental layout and the coordinate systems of the system, i.e., the hand coordinate system  $\Sigma_H$ , and the target coordinate system  $\Sigma_M$ , that are used in the experiments, respec-

tively. The target coordinate system  $\Sigma_M$  is set at  $(x = 0[mm], y = 0[mm], z = 550[mm])$  with respect to the hand coordinate system ( $\Sigma_H$ ). Figure 7 shows the 3 different target objects (No.1-No.3), each has different colors, sizes, shapes, and thickness, used in this experiment.




Fig. 8: The coordinate of target and end-effector of robot

For this 3 target objects, the clownfish was set at  $(x = 0[mm], y = 0[mm], z = 550[mm])$  represented to the hand of manipulator coordinate  $\Sigma_H$ . The octopoda was set at  $(x = -14[mm], y = 8[mm], z = 550[mm])$  and the coelacanth was set at  $(x = 13.5[mm], y = 8[mm], z = 550[mm])$  represented to the  $\Sigma_H$ . The experiment duration is 60 seconds, during the duration, the target to detect was changed twice, the sequence of target objects to recognized is set as "clownfish→octopoda→coelacanth".

#### 3.2 Experiment Result

The result of the whole duration of the experiment is shown in Fig.9. In Fig.9, the detection results of 3 objects in  $x, y, z$  axis are shown as blue, red and black lines. The dot-dashed line means the moment that the target to recognized was switched into a new one.

The Fig.10,11,12 shown the detection accuracy of 3 different objects, in these figures, the dot lines mean the desired result of detection, which also means the real position of target objects represented to the  $\Sigma_H$ , same as Fig.9, the detection results of  $x, y, z$  are also be represented as blue, red and black lines.

Due to the feature of the projection-based method, it is expected that the error of understanding will fluctuate depending on the target object. To the clown-

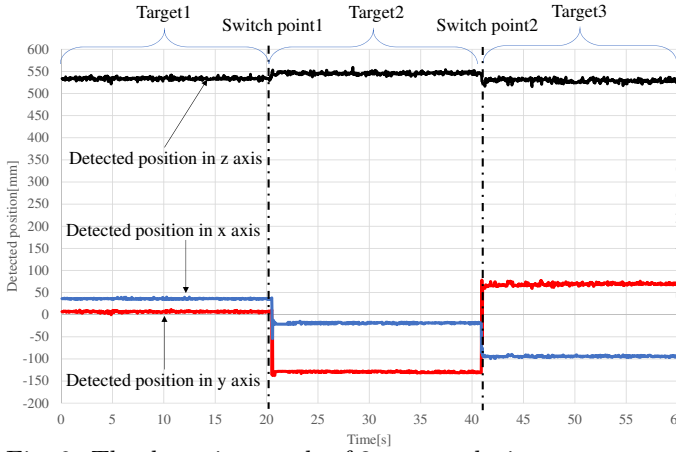


Fig. 9: The detection result of 3 targets during experiment

fish, target 1, the detection result is shown in Fig.9, according to the result, the detection error in  $x, y, z$  axis can be less than  $50[mm]$ , and when the target object is switched, the recognition of new objects can also be converged within half a second. When the target object is switched as octopoda, the detection error in  $y$  axis became larger, though the detection error in the other two axes is still small. To the last target, the coelacanth, the detection error in  $x, y$  axis are both became larger, the error in the  $x$  axis is up to  $100[mm]$ .

## 4 Conclusion

The projection-based method was proposed to adapt the detection towards arbitrary objects in unknown environments without pre-set models and aims to realize the automatically work. From the experiment, we can figure out the recognition accuracy of different objects, and the time consumed to switch the target have been proved short enough to adapt the real-time target change.

### 4.1 Reference

#### 参考文献

- 1) Kragic, Danica, and Henrik I. Christensen. "Survey on visual servoing for manipulation." Computational Vision and Active Perception Laboratory, Fiskartorpsv 15 (2002): 2002.
- 2) Chaumette, Francois, and Seth Hutchinson. "Visual servo control. I. Basic approaches." IEEE Robotics Automation Magazine 13.4 (2006): 82-90.
- 3) Malis, Ezio, Francois Chaumette, and Sylvie Boudet. "2D 1/2 Visual Servoing." IEEE Trans. on Robotics and Automation. 1999.
- 4) Scharstein, Daniel, and Richard Szeliski. "A taxonomy and evaluation of dense two-frame stereo correspondence algorithms." International journal of computer vision 47.1-3 (2002): 7-42.
- 5) W. Bach; J.K. Aggarwal (29 February 1988). "Motion Understanding: Robot and Human Vision". Springer Science & Business Media. ISBN 978-0-89838-258-7.
- 6) Song, Wei, Mamoru Minami, Yasushi Mae, and Seiji Aoyagi. "On-line evolutionary head pose measurement by feedforward stereo model matching." In Robotics and Automation, 2007 IEEE International Conference on, pp.4394-4400. IEEE, 2007.

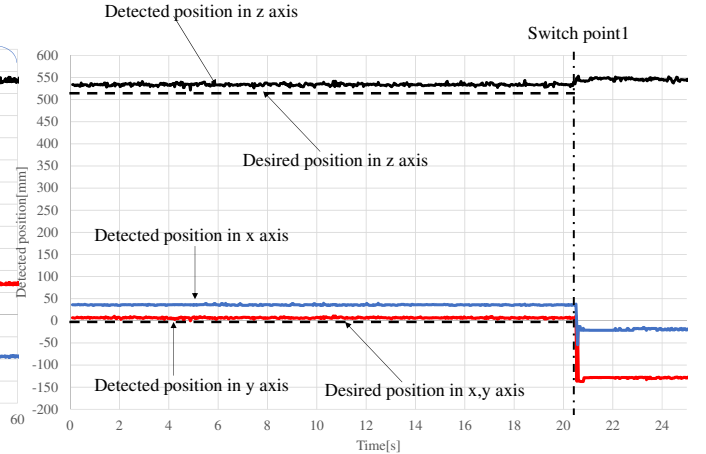


Fig. 10: The detection result of clownfish and desired position in  $x, y, z$  axis

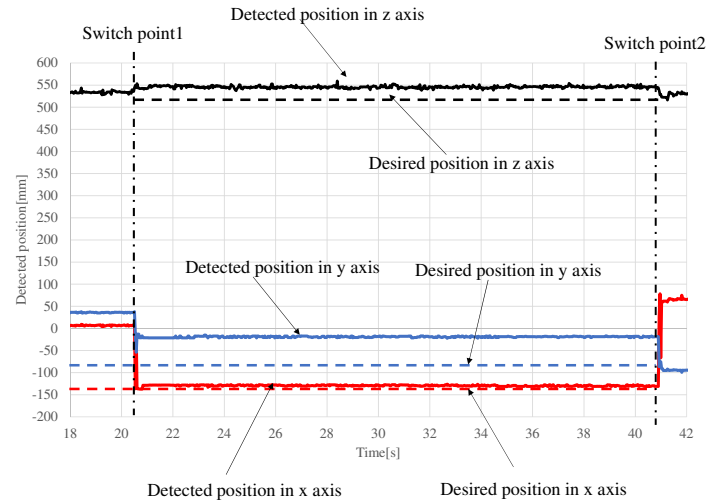


Fig. 11: The detection result of octopoda and desired position in  $x, y, z$  axis

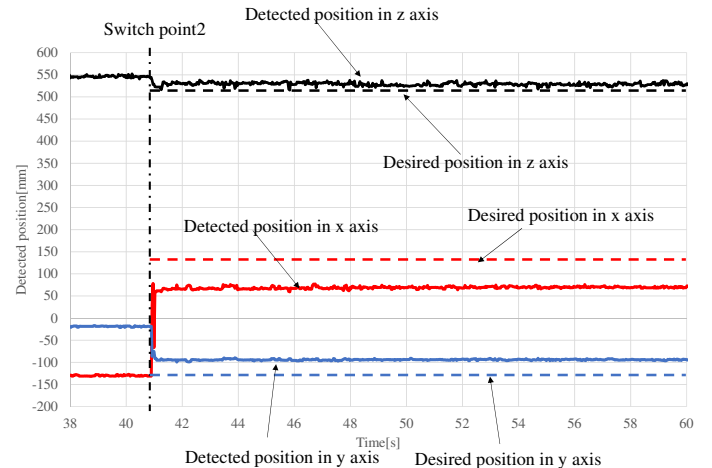


Fig. 12: The detection result of coelacanth and desired position in  $x, y, z$  axis

- 7) Mamoru Minami, Wei Song, "Hand-eye-motion Invariant Pose Estimation with On-line 1-step GA, - 3D Pose Tracking Accuracy Evaluation in Dynamic Hand-eye Oscillation-," Journal of Robotics and

Mechatronics, Vol.21, No.6, pp.709-719

- 8) Yejun Kou, Hongzhi Tian, Mamoru Minami, Takayuki Matsuno, "Improved eye-vergence visual servoing system in longitudinal direction with RM-GA", *Artif Life Robotics*, Vol.23, Issue 1, pp 131-139
- 9) Yu F, Minami M, Song W, Zhu J, Yanou A (2012) On-line head pose estimation with binocular hand-eye robot based on evolutionary model-based matching. *J Computer and Information Technology* 2(1):43-54
- 10) Minami M, Agbanhan J, Asakura T (2003) Evolutionary scene recognition and simultaneous position/orientation detection, in *Soft Computing in Measurement and Information Acquisition*. Springer, Berlin, pp 178-207
- 11) Graziano Chesi, Y. S. Hung "Global Path-Planning for Constrained and Optimal Visual Servoing" *IEEE Transactions on Robotics*, Volume: 23 Issue: 5

# 会話中の単語をもとにオートサジェスト機能を使って検索した 画像の提示手法

柴田大輔, 山口裕, ○大島千佳, 中山功一 (佐賀大学)

## Displaying Images Regarding Words from a Conversation Using an Autosuggest Functions

D. Shibata, Y. Yamaguchi, \* C. Oshima and K. Nakayama (Saga University)

**Abstract**— It is reported that displaying images may be more effective than only language to generate new idea. Especially, people may receive inspiration from unexpected images. In this paper, we presented a system called SWISS (Search Websites' Images using Search Suggestions) that searches images for brainstorming activities. SWISS searches Webpages using participants' utterances and extracts four words. Moreover, each word of the four words is listed with a letter of the alphabet/Hiragana character, which is selected at random and receives a suggested word. Then, SWISS searches images with extracted and suggested words. We conducted an experiment that three people discussed given themes with using SWISS and using SWISS without autosuggested function. The result showed that a participant could come up with a new idea from unexpected images displayed from SWISS.

**Key Words:** Idea generation support system, Speech recognition, Image retrieval, IBM Watson, Autocomplete function.

### 1 はじめに

これまで、多くの発想法や発想支援システム<sup>1)2)3)4)5)</sup>が開発されてきた。企業では日々、斬新なアイデアによる魅力的な製品を開発して成功したいと考えている。アイデアを生み出す際には、予想範囲内の一般的な情報はあまり役立たないといわれる<sup>7)</sup>。また、企業によっては、消費者が企業にアイデアを提案できるオンラインのオープンアイデア生成プラットフォームを持っている<sup>8)</sup>。このように、アイデアの幅を広げるために、多様な意見を収集しようとする<sup>9)</sup>。

Wang<sup>10)</sup>は、「アイデアを創出する段階で、画像を使うことは、言語を使うよりも、より効果的ではないか。」と述べている。“IdeaExpander<sup>11)</sup>”は、写真を表示することによってブレインストーミングをサポートするツールである。機械学習分類器を使用して、チャットを使ったブレインストーミングの中で、アイデアを引き出すキーワードを抽出し、Flickrに投稿された写真を検索する。「アイデアの複数のカテゴリや、あまり議論されていないカテゴリを含む画像は、生成されたアイデアの多様性を変換するのに役立つ<sup>10)</sup>」という。つまり、ブレインストーミングのとき、参加者がすでに発言した単語“X”の意味だけでなく、別の単語“Y”の意味も含む画像は、参加者のアイデアの生成を促進すると考えられる。

そこで本稿では、対面でのブレインストーミング中の、参加者の発話から抽出した単語のみならず、オートサジェスト機能を介して追加される単語の両方に基づいて、画像を表示するシステム“SWISS (Search Websites' Images using Search Suggestions)”を提案する。オートサジェスト機能は、過去に誰かが検索した単語の並びを表示する。つまり、参加者の発話から抽出した単語と何らかの関連を示す単語といえ、参加者に気付きを与える画像の検索につながる。また、オートサジェスト機能による単語との組み合わせは、画像の検索結果がゼロになる可能性は低い。

### 2 システム構成

Table 1にアプリケーションの開発環境、Fig.1にシステムの構成を示す。本システムは、Androidスマートフォン上で動作する。本システムを起動し、音声認識の待機状態になったスマートフォンを、ブレインストーミング参加者の発言が取得できる場所に設置して使用する。

参加者の発言はAndroidの音声認識APIであるAndroid Speech Recognizerに入力され、テキストに変換される。

テキストデータは、Bingの検索エンジンを利用したAPIであるBing Web Search APIに入力される。Bing Web Search APIは、テキストデータを使用してWebページを検索し、検索結果の先頭にあるWebページのURLを抽出する。

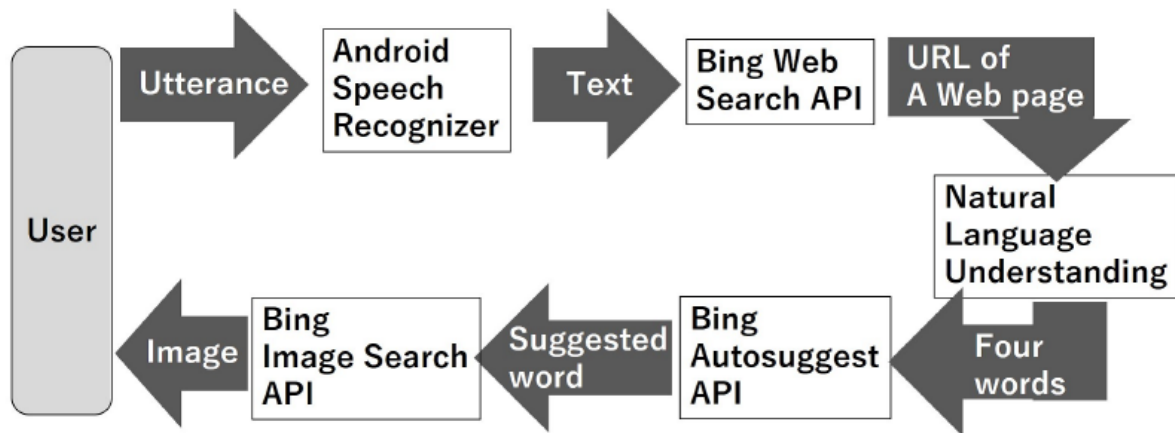
IBM WatsonのNatural Language Understanding (以下 Watson NLUと呼ぶ)は、Webページを分析し、そのページの概要を表す4つの単語を抽出する。

4つの単語はBing Autosuggest APIに入力され、Autosuggest機能により、各単語に1つずつ単語を追加する。

最後に、Bing Image Search APIは、Watson NLUによって抽出された4つの各単語と、Bing Autosuggest APIによってサジェストされた4つの各単語を、1対ずつ使用して画像を検索する。

Fig.2に示すように、検索結果となる画像は、スマートフォン内にてタイル状に並べられて表示される。また、検索クエリとなる単語を画面上部分に表示している。1画面に、1対の単語についての検索結果となる画像を6枚表示する。画面は、10秒ごとに切り替わり、4対の単語すべての画像を表示し終わると、音声認識の待機状態に戻る。





**Fig.1:** System searches images with two words, which are extracted from a brainstorming and selected from candidate words with the autosuggest function.

**Table 1:** Development Environment.

Classification	Specific
OS	Android7.1.1
Terminal	Nexus 5X
Integrated development environment	Android Studio
Development language	Java



**Fig.2:** An example of result of figures.

```
{
  "concepts": [
    {
      "text": "Computer",
      "relevance": 0.966702,
      "dbpedia_resource":
        "http://dbpedia.org/resource/Computer"
    },
    {
      "text": "Computer data storage",
      "relevance": 0.58942,
      "dbpedia_resource":
        "http://dbpedia.org/resource/Computer\_data\_storage"
    }
  ]
}
```

**Fig.3:** Watson NLU result.

2.1節で、Bing Web Search API によるWebページ検索方法、2.2節でBing Autosuggest API による単語のサジェストについて説明する。

### 2.1 Webページの分析

ディスカッション参加者の発言から検索されたWebページをWatson NLUが分析する。Watson NLUとは、自然言語処理を利用してテキストの意味的特徴を分析し、メタデータを抽出するIBM Watson のAPIの1つである。抽出できるメタデータは“Sentiment”, “Emotion”, “Keywords”, “Entities”, “Categories”, “Concepts” の6種類である。分析した結果はJSON形式のテキストデータとして返される。

Fig.3に分析結果の1例を示す。本稿では、分析結果の“Concepts”を利用する。“text”にWebページから抽出した単語を示し、“relevance”に単語とWebページの関連度の値を示している。関連度の値が高い単語を上位4つを選択し利用する。

## 2.2 Bing Autosuggest API



Fig.4: An example of result by Bing Autosuggest API

特定のカテゴリに集中せずにディスカッションを分散させるためBing Autosuggest APIを利用する。Bing Autosuggest APIは、ユーザが与えた検索クエリに応じて、関連する検索クエリの候補を返すAPIである。例えば、「りんご」という検索クエリを渡せば、「りんご病」、「りんご酢」、「りんご レシピ」といった検索クエリに関連がある単語を候補として返す。

Fig.4に示すように、本稿では、Watson NLUで抽出された各単語に、アルファベットまたはひらがながランダムに付加され、それぞれのアルファベットまたはひらがなを頭文字とした別の単語が候補として返される。

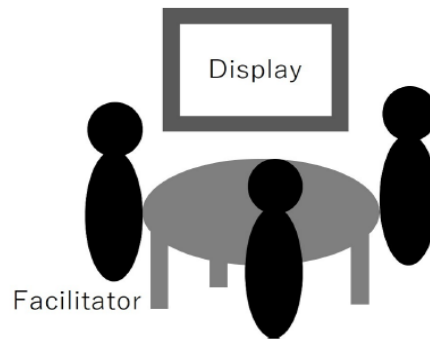


Fig.5: Position of the participants.

## 3 実験

### 3.1 目的

ブレインストーミングにおいて、画像検索クエリにAutosuggest 機能を含む (SWISS) システムと、Autosuggest 機能を含まないシステムを比較することによって、参加者の発話から得られる単語のみならず、関連する単語の意味も含む画像が、アイデア創出に有用であることを示す。

### 3.2 実験方法

実験には 12 人の大学生が参加した。そのうち 1 人は女性である。彼らはそれぞれ 3 人の参加者からなる 4 つのグループに分けられた。Fig.5 は参加者の位置を示す。3 人のうち 1 人を Facilitator (発話を促したり、話の流れを整理したりする役割の人) として、与えられた課題に対するブレインストーミングを行った。Facilitator の前に置かれたスマートフォンの画面は、ディスプレイとミラーリングを行い、ディスプレイ上に表示された。

Table 2 に実験を行った条件を示す。各グループは、A, B 両方の条件でブレインストーミングを行った。条件 A では、Web ページから抽出された 4 つの各単語に Bing Autosuggest API によってサジェストされた単語を付加し、各対の単語に基づいて画像検索を行う (SWISS をそのまま使う)。条件 B では、Bing Autosuggest API を使用せず、Web ページから抽出された 4 つの単語に基づいて画像検索を行う。参加者には条件 A と B の違いを知らせていない。

ブレインストーミングのために、2 つのテーマ (Q と R) を準備した。参加者は、各テーマについて、グループメンバーとそれぞれ 15 分ずつ話し合い、アイデアを出すように求められた。

#### テーマ Q

遠距離の関係にいる人は、相手がいなくて感情的に不安定になりがちです。

したがって、安心のためにカップルが存在感や愛情を伝えるツールやアプリケーションを提案してください。

い。  
テーマ R

Table 2: Conditions for the experiment

group	condition	theme
1	A	Q
	B	R
2	B	Q
	A	R
3	A	R
	B	Q
4	B	R
	A	Q

最近、大雨によって多くの土砂災害や洪水が発生しています。しかし、スマートフォンを持たない高齢者や、この災害の影響を受けないと思う高齢者は、すぐに避難することはできません。したがって、高齢者の緊急避難を促進するツールを提案してください。

ブレインストーミング中の発話は録音・録画された。両方のテーマでのブレインストーミング後、参加者に 2 つの条件での画像表示の違いを尋ねた。

本実験は、参加者に実験の目的を説明し、個人情報の取り扱いについて同意書により同意を得た上で行った。

### 3.3 結果

グループ 1 の参加者は、条件 B の画像が、条件 A の画像よりも会話に基づいており、より直接的に印象付けたと指摘した。同様に、グループ 4 の参加者は、予期しない画像が条件 A に表示されたと述べた。一方で、グループ 3 の参加者は、同じ画像が連続して表示されていたと指摘した。

以下に示すグループ 1 の議論の抜粋では、災害が発生したときに高齢者が安全な場所に避難させる方法を検討している。発話から、条件 A の画像が参加者の 1 人から新しいアイデアを引き出したことを示している。抜粋中の X, Y はそれぞれグループ 1 の参加者と司会者の 1 人のことを指す。

- 01X: 避難場所に行ったほうがお得になればいい  
 02Y: そうですね なるほどほんとそのコミュニティしか通じないようなクーポン作ったり  
 03X: ははは 避難に対して皆様に何を配ろう つりかな (画面を見る)  
 04Y: そうですね おじいちゃんたちだったらゲートボール入場料金  
 05X: ははは  
 06Y: 1回500円とかそういうの  
 07X: うん  
 08Y: 作ったり  
 普通にポイント制でもいいですけどね  
 ポイント作っちゃって協力してくれる企業とかで使える  
 09X: プレミアムだね  
 10Y: そういう風にしたら何かしらお得感 (車の画像表示が表示される)  
 があつた方がいいかもしれないですね (Xが画面を見る)  
 そっちの方向でいったら  
 11X: 避難バス  
 12Y: ああ  
 13X: ははは  
 14Y: 巡回します?  
 15X: 巡回 あはは  
 16Y: ああじゃあ 避難しましょうって感じで 避難しましょうと鳴らしながら1軒1軒まわってくる

参加者 X は、安全な場所に避難することで、高齢者が何らかの利益を得られるとの意見を述べた (01X)。参加者 Y は、それに対して地域限定のクーポンを提案した (02Y)。参加者 Y がクーポンシステムを実現するための概要を説明している間、様々な種類の車の画像がディスプレイに表示された (10Y)。その後、参加者 X は、避難経路を通して高齢者の家を訪れる「避難バス」というアイデアを提案した (11X)。車の画像を表示する前に、「車」という言葉を発した参加者は居なかった。「企業 (08Y)」という言葉が車の画像を検索するためのトリガーになったのではないかと推測される。

また、以下のようなフィードバックを参加者から得た。

- 議論が盛り上がっているときにはディスプレイを見なかった
- 画像から別の視点を得られた
- 音声認識の精度が良くなかった
- 同様の画像が連続して表示された
- 画像は役に立たなかった
- 話すことが無くなったときに画像が表示されるのを待った

### 3.4 考察

参加者の多くは、SWISS を用いた条件 A と、Bing Autosuggest API を使用していない条件 B との違いに気づいた。さらに、参加者は予想外のイメージか

ら新しいアイデアを思いつくことができた。したがって、Bing Image Search API が画像検索を行うとき、Bing Autosuggest API によって提案された単語が、Web ページから抽出された4つの単語に付加されると、新しいアイデアを提案する際に役に立つ可能性がある。

一方、画像を表示するタイミングを再検討すべきであることが判明した。SWISS は、人々が話していると断続的に画像を表示することができるが、人々が話をやめると、SWISS は画像を表示しなくなる。話が無いときに、画像の表示が求められた。

## 4 結論

ブレインストーミング支援のために画像を検索する SWISS (Search Websites' Images using Search Suggestions) を提案した。SWISS と Bing Autosuggest API を使用しない SWISS を用いて、3人の参加者がテーマに沿ってブレインストーミングする実験を行った。その結果、参加者は SWISS から表示された予期しない画像から新しいアイデアを提案することができた。

今後の課題として、参加者の発話が途切れたときにも画像を表示できるようにすることが挙げられる。

## 参考文献

- 1) A. F. Osborn: Applied Imagination, 2nd ed., New York: Scribner, 1957.
- 2) H. Ohiwa, K. Kawai, and M. Koyama: Idea processor and the KJ method, J. of Information Processing, **13(1)**, 44/48(1990).
- 3) S. Amitani, and K. Hori: Knowledge Nebula Crystallizer for Knowledge Liquidization & Crystallization-from a Theory to a Methodology of Knowledge Management, In Proc. of Expertise In Design, Design Thinking Research Symposium, **6**, 2003.
- 4) M. Miura, T. Sugihara, and S. Kunifuji: GKJ: Group KJ method support system utilizing digital pens, IEICE trans. on information and systems, **94(3)**, 456/464(2011).
- 5) A. Clayphan, A. Collins, and C. Ackad, B. Kummerfeld, and J. Kay: Firestorm: a brainstorming application for collaborative group work at tabletops, In Proc. of the ACM international conference on interactive tabletops and surfaces, 162/171(2011).
- 6) S. Tausch, D. Hausen, I. Kosan, A. Raltchev, and H. Hussmann: Groupgarden: supporting brainstorming through a metaphorical group mirror on table or wall, In Proc. of the 8th Nordic Conference on Human-Computer Interaction: Fun, Fast, Foundational, ACM, 541/550(2014).
- 7) T. Montag-Smit, and C. P. Maertz Jr: Searching outside the box in creative problem solving: The role of creative thinking skills and domain knowledge, J. of Business Research, **81**, 1/-10(2017).
- 8) L. Luo, and O. Toubia: Improving online idea generation platforms and customizing the task structure on the basis of consumers' domainspecific knowledge, J. of Marketing, **79(5)**, 100/114(2015).
- 9) B. A. Nijstad, W. Stroebe, and H. F. Lodewijkx: Cognitive stimulation and interference in groups: Exposure effects in an

idea generation task, *J. of experimental social psychology*, **38(6)**, 535/544(2002).

- 10) H. C. Wang, S. R. Fussell, and D. Cosley: From diversity to creativity: Stimulating group brainstorming with cultural differences and conversationally-searched pictures, In *Proc. Of the 2011 ACM conference on Computer supported cooperative work*, 265/274(2011).
- 11) H. C. Wang, D. Cosley, and S. R. Fussell: Idea expander: supporting group brainstorming with conversationally triggered visual thinking stimuli, In *Proceedings of the 2010 ACM conference on Computer supported cooperative work*, 103/106(2010).

# ニューラルネットワークの埋め込み安定性と汎化能力の関係

○古庄泰隆 池田和司 (奈良先端科学技術大学院大学)

## Stable embedding property of neural networks with ReLU activation and its relationship to generalization

\*Y. Furusho and K. Ikeda (NAIST)

**Abstract**— Model size determination is important in machine learning since a larger model leads to overfitting, that is, a small training loss and a high test loss. Surprisingly, a multi-layer perceptron (MLP) with the ReLU activation function has a smaller training loss as well as a smaller test loss as each layer gets wide. The gap between the two losses is related to the distance-preserving property of the transformation/embedding in each layer. To elucidate the mechanism, this paper theoretically derives an upper-bound of the gap for a random network and shows a wider MLP has a smaller gap. Our numerical experiments confirmed the validity of our analysis and the applicability to more general cases.

**Key Words:** neural network, wide network, generalization ability, isometry

### 1 はじめに

近年ディープニューラルネットワークは幅広い分野で圧倒的な性能を挙げており<sup>1, 2, 3)</sup>, この圧倒的な性能はニューラルネットワークのそのモデルの大きさが原因である<sup>4, 5, 6, 7, 8, 9)</sup>. 例えば活性化関数が ReLU 関数な多層パーセプトロン (MLP) はそのパラメータ数がデータセットのデータ数より大きい限り, そのデータセットの入出力関係を完全に表現する変換 (埋め込み) を実現できる能力を持っている<sup>10)</sup>. しかしながら, 大きなモデルは過学習を起しテスト誤差が悪化することが知られている. 言い換えると大きすぎるモデルは訓練誤差とテスト誤差のギャップが大きくなる.

驚くべきことに活性化関数が ReLU 関数な MLP は隠れ層のユニット数が多くなるほど訓練誤差はもちろんだが, 上記のギャップまで小さくなることが報告されている<sup>11, 12)</sup>. 我々の実験でもこの結果を確認した (Fig.1). モデルのサイズに依存するモデルの複雑度に応じた現在の理論では上記の幅の広いネットワークの小さなギャップを説明することはできない. これはこれらの理論がモデルの複雑度が小さいほどギャップも小さくなるというものだからである. 例えばモデルの複雑度の1つとして VC 次元が挙げられるがこれは隠れ層のユニット数が多くなると増加する. 他の複雑度である Rademacher 複雑度<sup>13, 14, 12, 15)</sup>, stability<sup>16)</sup>, robustness<sup>17)</sup> は隠れ層のユニット数には依存しない. よってこれらの複雑度では幅の広いネットワークの小さなギャップを説明できない. これを説明するために新しい理論が必要である.

我々は訓練誤差とテスト誤差のギャップがニューラルネットワークの隠れ層の変換がもつデータ間の距離関係を保つ性質 (埋め込み安定性) に関係するという理論を示した. さらに我々は重みがランダムな MLP を解析し, 隠れ層のユニット数が多いほど埋め込みが安定することを示した. 上記2つの結果より幅の広いネットワークは小さなギャップを達成することを示すことができる. 我々の実験結果でも上記の理論的性質が成立すること, さらに学習後のネットワークにも我々の理論が適用できることを確認した.




Fig. 1: 活性化関数が ReLU で隠れ層が 2 層の MLP の交差エントロピー誤差と誤識別率. 異なる幅  $d$  の MLP に MNIST データセットを正則化なしの確率的勾配降下法で 10 回学習させ, 各指標の平均と標準偏差をプロットした.

### 2 問題設定とモデルの定式化

我々はニューラルネットワークの隠れ層による変換が持つデータ間の距離関係を保つ性質 (埋め込み安定性) と訓練誤差とテスト誤差のギャップの関係性について解析した. この章では問題設定の説明とニューラルネットワークの定式化を行う.

#### 2.1 問題設定

訓練セット  $S := \{(x(n), y(n))\}_{n=1}^N$  とテストセット  $S' := \{(x'(n), y'(n))\}_{n=1}^N$  が与えられている. ただし文章から明らかな場合データのインデックスを省略する. それぞれのデータは入力  $x \in \mathcal{X} \subset \mathbb{R}^D$  とそれに対応するクラスラベル  $y \in \mathcal{Y} := [K]$  のペアで構成される. ここで簡単のため同じデータのインデックスのクラスラベルは訓練セットとテストセットで一致する  $y(n) = y'(n)$  とし, 入力データは単位球に属する  $x \in \mathcal{X} \subset \mathbb{B}_1^D$  とする. これらの仮定を取り払い次章の定理を一般化することができるが, ここでは簡単のためこの仮定をおく.

## 2.2 ニューラルネットワーク

隠れ層が  $L$  層あり各隠れ層にユニットが  $d$  個ある次の MLP:  $x \mapsto \hat{y}$  を考える (Fig.2). ただし  $h^0 := x$  として  $\phi(\cdot) := \max(0, \cdot)$  は ReLU 活性化関数とする. また  $\sigma$  は Softmax 関数であり式 4 のように定義される.

$$u_i^l = \sum_{j=1}^d W_{ij}^l h_j^{l-1}, \quad (1)$$

$$h_i^l = \phi(u_i^l), \quad (2)$$

$$v_i = \sum_{j=1}^d V_{ij} h_j^L, \quad (3)$$

$$\hat{y}_i = \sigma(v)_i := \frac{\exp(v_i)}{\sum_{k=1}^K \exp(v_k)}. \quad (4)$$

ここで隠れ層による変換は特徴抽出器 (式 1,2), 出力層は線形分類器 (式 3,4) として考えることができる. MLP の重みは He の方法<sup>18)</sup> で初期化する.

$$W_{ij}^l \sim \mathcal{N}\left(0, \frac{2}{D}\right). \quad (5)$$

次のように隠れ層による変換のデータ間の距離関係を保つ性質 (埋め込み安定性) を定義する.

**Definition 1** 隠れ層の変換が次の性質 ( $\epsilon$ -isometry) を満たす時, その埋め込みは安定であるという. ただし  $h(n), h'(n)$  は入力データ  $x(n), x'(n)$  の隠れ層による埋め込みである.

$$\forall n \in [N], \quad \left| \|h(n) - h'(n)\|^2 - \|x(n) - x'(n)\|^2 \right| \leq \epsilon. \quad (6)$$

MLP は次の交差エントロピーを最小化するように確率的勾配降下法で学習する.

$$\ell(\hat{y}, y) := \sum_{k=1}^K \text{vec}(y)_k \log(\hat{y}_k). \quad (7)$$

$\text{vec}(y)$  はクラスラベル  $y$  の one-hot ベクトルである.

訓練誤差とテスト誤差のギャップは次で定義される. ただし  $\hat{y}(n), \hat{y}'(n)$  は  $x(n), x'(n)$  の MLP の出力である.

$$\text{Gap} := \frac{1}{N} \sum_{n=1}^N \{ \ell(\hat{y}'(n), y'(n)) - \ell(\hat{y}(n), y(n)) \}. \quad (8)$$




Fig. 2: MLP の構造. 隠れ層による変換は特徴抽出器として出力層は線形分類器として考えることができる.

## 3 理論結果

本章ではまず訓練誤差とテスト誤差のギャップが MLP の隠れ層の変換が持つデータ間の距離関係を保つ性質 (埋め込み安定性) に関係するという理論を示す. その後, 重みがランダムな MLP を解析し, 隠れ層のユニット数が多いほど埋め込みが安定することを示す. 上記 2 つの結果は幅の広いネットワークが小さなギャップを達成することを意味している. 更に上記の理論が実問題でも成立するか検証するため, 重みをランダムに初期化した MLP と学習後の MLP の埋め込み安定性を MNIST データセットに対して計算した. この実験結果については次章で示す.

### 3.1 埋め込み安定性と訓練誤差とテスト誤差のギャップ

埋め込み安定性と訓練誤差とテスト誤差にギャップの関係を導くため次の仮定を出力層におく.

**Assumption 1** 出力層の重みと出力層の出力が次を満たすと仮定する.

$$\|V\|_{\text{op}} \leq L_V, \quad (9)$$

$$\forall n \in [N], \quad \hat{y}(n)_{y(n)}, \hat{y}'(n)_{y'(n)} \geq L_Y. \quad (10)$$

ただし  $\|\cdot\|_{\text{op}}$  は作用素ノルムである.

我々は誤差関数と出力層の Lipschitz 性を用いることで, 埋め込み安定性が訓練誤差とテスト誤差のギャップに関係することを示した.

**Lemma 1** Assumption1 の下で次式が成立する.

$$\text{Gap} = \frac{1}{N} \sum_{k=1}^K \sum_{n \in I_k} \{ \ell(\hat{y}'(n), y'(n)) - \ell(\hat{y}(n), y(n)) \} \quad (11)$$

$$\leq \frac{1}{NL_Y} \sum_{k=1}^K \sum_{n \in I_k} \|\hat{y}(n) - \hat{y}'(n)\| \quad (12)$$

$$\leq \frac{L_V}{NL_Y} \frac{\sqrt{K-1}}{K} \sum_{k=1}^K \sum_{n \in I_k} \|h^L(n) - h^{L'}(n)\|. \quad (13)$$

ただし  $I_k$  はクラスラベルが  $k$  に属するデータのインデックスの集合である.

さらに埋め込み安定性 (Definition1) と逆三角不等式を利用することでギャップを埋め込み安定性で上から抑えることができる.

**Theorem 1** MLP の隠れ層による埋め込みが安定ならば次式が成立する.

$$\text{Gap} \leq \frac{L_V}{NL_Y} \frac{\sqrt{K-1}}{K} \sum_{k=1}^K \sum_{n \in I_k} \sqrt{\|x(n) - x'(n)\| + \epsilon} \quad (14)$$

$$\leq \frac{L_V}{L_Y} \frac{\sqrt{K-1}}{K} \sqrt{2 + \epsilon}. \quad (15)$$

Theorem1 は埋め込みが安定するなら ( $\epsilon$  が小さいなら) ギャップも小さくなることを示唆している.



### 3.2 1層の隠れ層の埋め込み安定性

1層の隠れ層の埋め込みは次のように安定する。この結果は多様体上のデータに対する結果<sup>19)</sup>を任意のデータ点への結果へと拡張したものである。

**Theorem 2** 式5に従いランダムに初期化した $d$ 個のユニットを持つ隠れ層の埋め込みは少なくとも確率 $1 - \exp\left(\frac{-3t^2}{12+4t\|x-x'\|^2}\right) - 2 \exp\left(\frac{-\|x-x'\|}{4\pi}\right)$ で次式の通り安定である。

$$\begin{aligned} & \left| \|\phi(Wx) - \phi(Wx')\|^2 - \|x - x'\|^2 \right| \\ & \leq \frac{D}{d}t + \frac{\|x\|\|x'\|}{\pi} \psi(\angle(x, x')) \end{aligned} \quad (16)$$

ただし $\angle(x, x') := \arccos \frac{x^T x'}{\|x\|\|x'\|}$ は2点 $x, x'$ の角度で、

$$\begin{aligned} \psi(\angle(x, x')) & := \\ & 2\pi - \sin \angle(x, x') - (\pi - \angle(x, x')) \cos \angle(x, x'). \end{aligned} \quad (17)$$

Theorem2は隠れ層のユニットの数を増やす( $d$ を大きくする)と埋め込みが安定することを示唆している。さらに式16の右辺の2項目はReLU活性化関数によるものである。よってReLU活性化関数により同じクラス間のデータはより埋め込みが安定する。なぜなら $\psi(\angle(x, x'))$ は単調増加関数(Fig.3)で、同じクラスのデータ間の角度 $\angle(x, x')$ は小さいからである。

### 3.3 ニューラルネットワークの埋め込み安定性

前節では1層の隠れ層の埋め込み安定性を解析したが、本節ではこれを一般化した隠れ層が $L$ 層のMLPの埋め込み安定性を解析する。

**Lemma 2** ReLU活性化関数はその性質からデータを縮小する。

$$\|\phi(W^l h^l) - \phi(W^l h^{l'})\| \leq \|W^l h^l - W^l h^{l'}\|. \quad (18)$$

この右辺にJohnson-Lindenstraussの補題<sup>20)</sup>を適用すると次式が高確率で成立する。

$$\begin{aligned} \|\phi(W^l h^l) - \phi(W^l h^{l'})\| & \leq \|W^l h^l - W^l h^{l'}\| \\ & \leq \left(1 + \mathcal{O}\left(\frac{1}{\sqrt{d}}\right)\right) \|h^l - h^{l'}\|. \end{aligned} \quad (19)$$

Lemma2を再帰的に適用することで次の $L$ 層の隠れ層による変換のLipschitz性に関する補題を得ることができる。




Fig. 3:  $\psi(\angle(x, x'))$ は単調増加関数である。

**Lemma 3** 次式が高確率で成立する。

$$\begin{aligned} \|h^L - h^{L'}\| & = \|\phi(W^L h^{L-1}) - \phi(W^L h^{L-1'})\| \quad (20) \\ & \leq \left(1 + \mathcal{O}\left(\frac{1}{\sqrt{d}}\right)\right)^L \|x - x'\|. \end{aligned} \quad (21)$$

そしてLemma3をLemma1へと代入することで次の訓練誤差とテスト誤差のギャップに関する定理を得れる。

**Theorem 3** 次式が高確率で成立する。

$$\begin{aligned} \text{Gap} & \leq \frac{L_V \sqrt{K-1}}{L_Y K} \left(1 + \mathcal{O}\left(\frac{1}{\sqrt{d}}\right)\right)^L \|x - x'\| \quad (22) \\ & \leq 2 \frac{L_V \sqrt{K-1}}{L_Y K} \left(1 + \mathcal{O}\left(\frac{1}{\sqrt{d}}\right)\right)^L. \end{aligned} \quad (23)$$

Theorem3は隠れ層のユニットの数を増やす( $d$ を大きくする)と埋め込みが安定することを示唆している。しかしながら、この定理の上界は式18によりReLU活性化関数の影響を無視しているという点で緩い。実際はTheorem2から分かる通り同じクラス間のデータはより埋め込みが安定することが考えられる。

## 4 実験結果と議論

### 4.1 ニューラルネットワークの埋め込み安定性

我々の理論結果が実問題でも成立するか検証するために重みをランダムに初期化したMLPと確率的勾配降下法で学習したMLPの埋め込み安定性をMNISTデータセットに対して計算した。ただし理論結果では埋め込み安定性は隠れ層のユニットの数 $d$ と隠れ層の数 $L$ に依存するため、異なるユニット数 $d = 100, 1000$ (Fig.4)と異なる隠れ層の数 $L = 1, 5$ (Fig.5)で埋め込み安定性を計算した。

Fig.4より隠れ層のユニット数が多くなるとMLPの埋め込みが安定することが分かる。さらに角度の近いデータ(同じクラスに属するデータ)の埋め込みがより安定することも分かった。これは我々の理論結果と一致する。さらに学習後のMLPの埋め込み安定性もランダムに初期化したMLPと同じ傾向があることが分かる。これは我々の理論結果が学習後のMLPにも適用できることを示唆している。

一方でFig.5では層の数が多くなると埋め込み安定性が悪くなることが分かる。この結果も理論結果と一致する。訓練誤差とテスト誤差のギャップという性能から見るとMLPの深さは悪い影響を与えることが分かった。では深さはどういった性能を向上し最終的に高い汎化能力を達成できるのだろうか。この疑問に対して次節で実験的な結果から答えを与える。

### 4.2 ニューラルネットワークのデータ分離性

MLPの深さが与える利点を検証するために2つのデータに対する隠れ層の出力の角度を計算した(Fig.6)。

Fig.6より隠れ層の数が多いほど学習後はデータの分離性能が向上しているのが分かる。出力層は線形分類器なので、この結果は訓練誤差を小さくすることを示唆している。したがって層の深さに関して訓練誤差とテスト誤差と訓練誤差のギャップにはトレードオフがあることが分かる。

## 5 結論

幅の広いニューラルネットワークの高い汎化能力の原因を明らかにするために、我々は訓練誤差とテスト誤差のギャップがニューラルネットワークの隠れ層の変換が持つデータ間の距離関係を保つ性質 (埋め込み安定性) に関係するという理論を示した。さらに我々はランダムな MLP を解析し、隠れ層のユニット数が多いほど埋め込みが安定することを示した。上記2つの結果より幅の広いネットワークは小さなギャップを達成できることを示すことができる。さらに我々の実験結果でも上記の理論的性質が成立すること、さらに学習後の MLP にも我々の理論が適用できることを確認した。




Fig. 4: 隠れ層が5層でユニット数が $d$ のディープニューラルネットワークの埋め込み安定性.




Fig. 5: 隠れ層が $L$ 層でユニット数が1000のディープニューラルネットワークの埋め込み安定性.

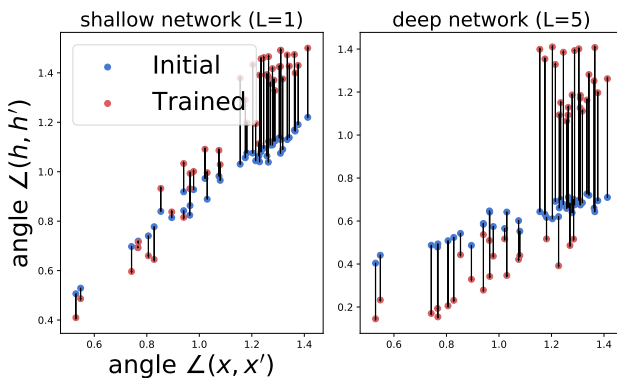


Fig. 6: 隠れ層が $L$ 層でユニット数が1000のディープニューラルネットワークのデータ分離性.

## 参考文献

- 1) Yann LeCun, Yoshua Bengio and Geoffrey Hinton: Deep learning, *nature*, **521**-7553, 436 (2015)
- 2) Olga Russakovsky, Jia Deng, Hao Su, Jonathan Krause, Sanjeev Satheesh, Sean Ma, Zhiheng Huang, Andrej Karpathy, Aditya Khosla, Michael Bernstein et al.: Imagenet large scale visual recognition challenge, *International Journal of Computer Vision*, **115**-3, 211/252 (2015)
- 3) David Silver, Aja Huang, Chris J Maddison, Arthur Guez, Laurent Sifre, George Van Den Driessche, Julian Schrittwieser, Ioannis Antonoglou, Veda Panneershelvam, Marc Lanctot et al.: Mastering the game of Go with deep neural networks and tree search, *nature*, **529**-7587, 484 (2016)
- 4) Yoshua Bengio et al.: Learning deep architectures for AI, *Foundations and trends® in Machine Learning*, **2**-1, 1/127 (2009)
- 5) Guido F Montufar, Razvan Pascanu, Kyunghyun Cho and Yoshua Bengio: On the number of linear regions of deep neural networks, In *Advances in neural information processing systems*, 2924/2932 (2014)
- 6) Matus Telgarsky: benefits of depth in neural networks, In *Conference on Learning Theory*, 1517/1539 (2016)
- 7) Maithra Raghu, Ben Poole, Jon Kleinberg, Surya Ganguli and Jascha Sohl-Dickstein: On the Expressive Power of Deep Neural Networks, In *International Conference on Machine Learning*, 2847/2854 (2017)
- 8) Dumitru Erhan, Yoshua Bengio, Aaron Courville, Pierre-Antoine Manzagol, Pascal Vincent and Samy Bengio: Why does unsupervised pre-training help deep learning?, *Journal of Machine Learning Research*, **11**-Feb, 625/660 (2010)
- 9) Yasutaka Furusho, Takatomi Kubo and Kazushi Ikeda: Roles of pre-training in deep neural networks from information theoretical perspective, *Neurocomputing*, **248**, 76/79 (2017)
- 10) Chiyuan Zhang, Samy Bengio, Moritz Hardt, Benjamin Recht and Oriol Vinyals: Understanding deep learning requires rethinking generalization, *International Conference on Learning Representations*, (2017)
- 11) Behnam Neyshabur, Ryota Tomioka and Nathan Srebro: In search of the real inductive bias: On the role of implicit regularization in deep learning, *International Conference on Learning Representations*, (2015)
- 12) Behnam Neyshabur, Srinadh Bhojanapalli, David McAllester and Nati Srebro: Exploring generalization in deep learning, In *Advances in Neural Information Processing Systems*, 5947/5956 (2017)
- 13) Peter L Bartlett and Shahar Mendelson: Rademacher and Gaussian complexities: Risk bounds and structural results, *Journal of Machine Learning Research*, **3**-Nov, 463/482 (2002)
- 14) Behnam Neyshabur, Ryota Tomioka and Nathan Srebro: Norm-based capacity control in neural networks, In *Conference on Learning Theory*, 1376/1401 (2015)
- 15) Peter L Bartlett, Dylan J Foster and Matus J Telgarsky: Spectrally-normalized margin bounds for neural networks, In *Advances in Neural Information Processing Systems*, 6240/6249 (2017)
- 16) Olivier Bousquet and André Elisseeff: Stability and generalization, *Journal of machine learning research*, **2**-Mar, 499/526 (2002)
- 17) Huan Xu and Shie Mannor: Robustness and generalization, *Machine learning*, **86**-3, 391/423 (2012)
- 18) Kaiming He, Xiangyu Zhang, Shaoqing Ren and Jian Sun: Delving deep into rectifiers: Surpassing human-level performance on imagenet classification, In *Proceedings of the IEEE international conference on computer vision*, 1026/1034 (2015)



- 19) Raja Giryes, Guillermo Sapiro and Alexander M Bronstein: Deep neural networks with random gaussian weights: A universal classification strategy?, *IEEE Trans. Signal Processing*, **64-13**, 3444/3457 (2016)
- 20) Stéphane Boucheron, Gábor Lugosi and Pascal Massart: *Concentration inequalities: A nonasymptotic theory of independence*, Oxford university press (2013)

# ディープラーニングによる牛の妊娠鑑定

○井手祐太<sup>†</sup>, 中山功一<sup>†</sup>, 福田修<sup>†</sup>, 山下健一<sup>‡</sup> (佐賀大学<sup>†</sup>, 産総研<sup>‡</sup>)

## Pregnancy examination of cow using deep learning

\* Yuta Ide<sup>†</sup>, Koichi Nakayama<sup>†</sup>, Osamu Fukuda<sup>†</sup>, Kenichi Yamashita<sup>‡</sup> (Saga University<sup>†</sup>, AIST<sup>‡</sup>)

**Abstract**— This research aimed to estimate whether breeding cattle become pregnant or not on the day about 14 after artificial insemination. We constructed a classifier to estimate the cattle's pregnant based on color doppler ultrasonography (CDUS) images of the cattle's corpus luteum. In the experiments, we prepared two-class dataset which includes the corpus luteum images of non-conception/conception cattle. A framework of the deep learning, TensorFlow, was adopted and trained by these images to construct the classifier. In the experimental results, over 90% accuracy rate was obtained with the test images randomly selected from the dataset. However, the accuracy rate decreased in the cross-validation test, in which the test images of the specified cattle were not included into the training dataset. More data will be required to improve estimation accuracy and verify validity of the proposed method.

**Key Words:** Deep learning, Cattle, Pregnancy

## 1. はじめに

### 1.1 研究背景と目的

乳牛/肉牛の妊娠期間は280日であり、妊娠周期(発情のサイクル)は20日である。人工授精後、通常であれば2周期(40日)後に、妊娠の成否が判明するが、これを1周期(20日)に短縮できれば、出産までに要する期間が20日ほど短くなる。これは乳牛/肉牛の生産性が7%程度向上することを意味し、1頭が100~1000万円という価格を考慮すると、大きな経済効果がある。

通常、牛の発情期に合わせて人工授精を行うが、一周期目(20日目)では妊娠鑑定ができない。再度、人工授精をすることで、牛が妊娠していた場合に流産へとつながるため、2周期目(40日目)まで人工授精ができない。本論文では、14日目の時点の牛の子宮内の黄体の超音波検査画像(エコー画像/ドップラー画像、以下、黄体カラードップラー画像と記す)<sup>9)10)</sup>から、その牛の妊娠鑑定を行うことを目的とする。

### 1.2 先行研究

現在まで、牛における早期の妊娠鑑定について、様々な研究が行われている。例えば、吉野らは、人工授精後3週間以内に、ISG15やMX2といった指標を用いて、妊娠鑑定について検証を行っている<sup>2)</sup>。金澤らは、人工授精後7日目において黄体の血流面積、14日目において黄体の血流面積と血流速度を用いて妊娠鑑定を検証している<sup>1)</sup>。本研究では、ディープラーニング<sup>6)</sup>を用いて、黄体画像から妊娠鑑定を行う。黄体画像から、プログラムが即座に妊娠鑑定を行うことによって、妊娠鑑定の迅速化・簡素化が見込まれる。

## 2. TensorFlow

### 2.1 本研究でのニューラルネットワーク<sup>7)8)</sup>の利用

本研究で作成するのは、牛の妊娠鑑定を行う画像分類モデルである。収集した黄体画像をTensorFlow<sup>3)</sup>に学習させ、画像分類モデルを作成する。超音波で撮影された牛の画像を入力とし、その入力を画像分類モデルに入力する。入力を画像分類モデルが分析し、黄体画像が撮影された牛の妊娠鑑定を出力として算出する。

### 2.2 TensorFlowの概要

TensorFlowは、Googleから2015年11月に発表された、オープンソースの機械学習ライブラリである。機械学習ライブラリとは、機械学習を実装する際に、必要なプログラムや、あると便利なプログラムをまとめたものである。これを使用することで、複雑な計算や処理のプログラミングが簡単になる。PythonとC++で使用可能であるが、C++では一部の機能が制限される。

TensorFlowの特徴として、グラフの可視化ができるTensorBoardが使用できる、オープンソースなので導入コストがあまりかからない、利用者が多いので情報を比較的容易に収集できる、等が挙げられる。本研究では、このTensorFlowを使用して、画像分類モデルを作成する。

### 2.3 本研究でのニューラルネットワークの構造

本研究では、学習手法として畳み込みニューラルネットワーク<sup>4)5)</sup>を使用している。層の総数は6層である。Fig.1に構造の概要を示している。

畳み込み層は、画像の一定範囲にフィルターを適用した特徴を一つの入力として入力する畳み込みを行う層である。本研究では、その一定範囲を、Fig.1における第1畳み込み層では3×3ピクセル、第2畳み込み層では5×5ピクセルとしている。入力する一定範囲の移動幅は横、縦共に1ピクセルである。つまり、元の入力の大きさと畳み込み後の出力の大きさは同じとなる。

プーリング層は、画像を圧縮するプーリングを行う層である。本研究では、画像の一定範囲の最大値を取るマックスプーリングという方法を取っている。一定範囲とは2×2ピクセルである。全結合層とは、それまでの計算結果をまとめて、出力する層である。

Softmax 回帰層は、全結合層から出力された計算結果を元に、どの解答にどれくらい当てはまるかを確率

で出力しなおす層である。これら6つの層を経由して、最終的に、期待される解答である確率が最も高い解答が算出される。

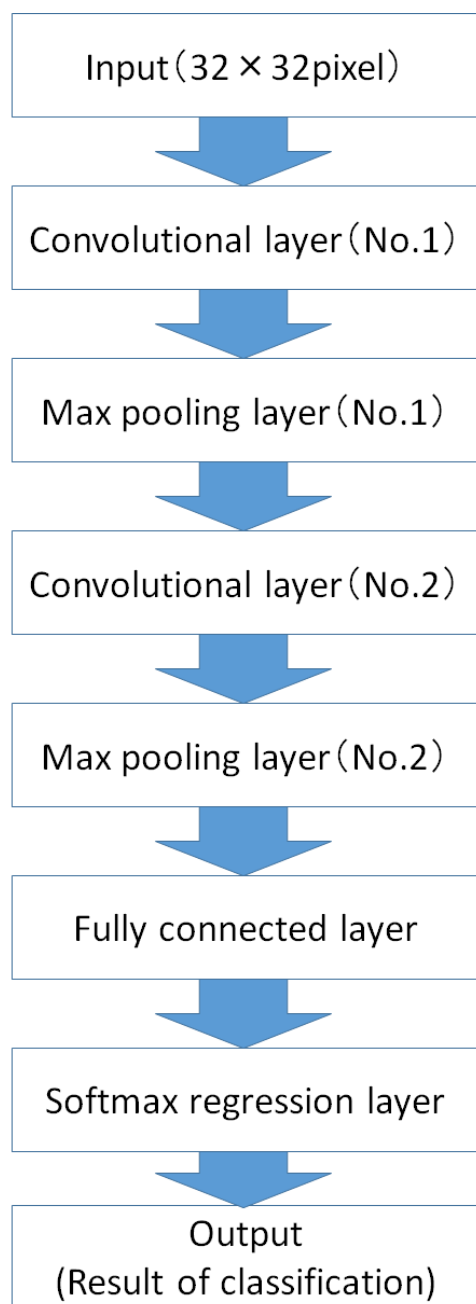


Fig. 1: Network architecture in this research

### 3. 実験で用いる黄体画像

#### 3.1 実験概要

乳用牛の個体に人工授精を行う。人工授精後 10~18 日(14 日前後)経過時点で、その個体の黄体カラー Doppler 画像を撮影する。黄体カラー Doppler 画像の詳細については、次節で説明する。人工授精後 40 日経過時点で、その個体の妊娠の成否を確認する。人工授精後 14 日前後経過時点での黄体カラー Doppler 画像と、40 日経過時点での妊娠の成否を 1 対 1 で紐づけ

する。紐づけしたものを黄体画像として収集する。

複数頭の牛において、複数回の人工授精を行い、上で述べたような黄体画像を複数収集する。収集した黄体画像を、学習用黄体画像とテスト用黄体画像の 2 種類に分割する。学習用黄体画像は、黄体画像から妊娠の成否を予測する画像分類モデルを作成するためのものである。テスト用黄体画像は、学習用黄体画像以外の黄体画像であり、どれだけ正確に妊娠の成否を分類できるかを確認するための黄体画像である。以下の 4 種類の実験を行う。

#### ・実験 1：全黄体画像による分類

妊娠の成否を分類したい乳用牛の学習用黄体画像も含めて、全ての黄体画像を用いて実験を行う。すなわち、分類したい乳用牛が過去に妊娠していた場合の黄体画像と、妊娠していなかった場合の黄体画像を含めて作成した画像分類モデルが、テスト用黄体画像からどれだけ正確に 40 日経過時点での妊娠の成否を分類できるかを検証する。

#### ・実験 2：判定対象個体以外の黄体画像による分類

妊娠の成否を分類したい乳用牛の学習用黄体画像が存在せず、同品種の乳用牛の黄体画像のみ存在する場合を想定した実験を行う。すなわち、乳用牛 1 頭分の全ての黄体画像をテスト用黄体画像とし、それ以外の全ての牛の黄体画像を学習用黄体画像として作成する画像分類モデルが、どれだけ正確に 40 日経過時点での妊娠の成否を分類できるかを検証する。テスト用黄体画像と学習用黄体画像を入れ替えながら、乳用牛の黄体画像が、全ての牛について 1 回ずつテスト用黄体画像となるように繰り返す。

#### ・実験 3：異なる品種の黄体画像による分類

妊娠の成否を分類したい牛とは品種が異なる牛の黄体画像しかない場合を想定した実験を行う。すなわち、実験 1 で用いた乳用牛の全黄体画像を用いて作成した画像分類モデルを用いて、品種の異なる肉用牛の人工授精後 13~15 日(14 日前後)経過時点における黄体画像から、どれだけ正確に 40 日経過時点での妊娠の成否を分類できるかを検証する。肉用牛のテスト用黄体画像を入れ替えながら、全ての肉用牛において、肉用牛全ての黄体画像がそれぞれ 1 回ずつテスト用黄体画像となるまで繰り返す。

#### ・実験 4：1 頭だけの黄体画像による分類

妊娠の成否を分類したい乳用牛 1 頭分の過去の黄体画像しかない場合を想定した実験を行う。すなわち、まず、乳用牛の全 55 頭分の黄体画像を個体毎に分ける。分けられた 1 頭分の黄体画像において、1 組の黄体画像をテスト用黄体画像とし、それ以外の黄体画像全てを学習用黄体画像とする。学習用黄体画像を用いて画像分類モデルを作成し、テスト用黄体画像の黄体カラー Doppler 画像を読み込ませ、ラベルを出力させる。これを、その個体の全ての黄体画像において行う。テ

スト用黄体画像を入れ替えながら実験する。これを、黄体画像の数が実験の要件を満たさない(黄体画像の数が1組のみ)2頭を除いた53頭の乳用牛に対して行う。

### 3.2 画像分類モデルの作成とテストのためのデータ準備

#### 3.2.1 黄体画像(乳用牛)

乳用牛の黄体、つまり子宮を超音波検査によって撮影し、黄体カラー Doppler 画像を収集する。黄体カラー Doppler 画像とは、超音波検査によって、黄体周辺とその部分における血流の分布を1枚の画像に写したものである。収集するのは、人工受精後14日前後経過時点での黄体画像である。Fig. 2は、実際に撮影された黄体カラー Doppler 画像である。白黒で表されている台形の部分に、黄体とその周辺部分が写されている。カラー Doppler と呼ばれる手法によって、黄体周辺に流れている血液の方向や面積も同時に写されている。血流の方向や面積は、Fig. 3において、曲線で囲われている部分のように、色と着色されている部分の面積で表されている。




Fig. 2: Example of color doppler ultrasonography image (dairy cattle)




Fig. 3: Visualized luteal blood flow by color doppler (surrounded by curve line)

人工受精後14日前後経過時点での乳用牛の黄体カラー Doppler 画像を収集する。同じ乳用牛において、それから26日前後経過時点、即ち人工受精後40日経過時点で、妊娠の成否を確認する。人工受精後14日前後経過時点の乳用牛の黄体カラー Doppler 画像と、人工受精後40日経過時点での妊娠の成否を1対1で紐づける。

全部で55頭の乳用牛について93回分の人工授精を行った。93回分の人工授精のうち、受胎(40日経過時点で妊娠していた)という結果が出たのが40回分、不受胎(40日経過時点で妊娠していなかった)という結果が出たのが53回分である。収集した黄体カラー Doppler 画像の総枚数は1406枚であり、その内、受胎と紐づけられている黄体カラー Doppler 画像が696枚、不受胎と紐づけられている黄体カラー Doppler 画像が710枚である。

このように、黄体カラー Doppler 画像の撮影と妊娠の成否の確認を行い、1406枚の黄体カラー Doppler 画像と、それらの黄体カラー Doppler 画像1枚ずつに妊娠の成否を紐づける。1枚の黄体カラー Doppler 画像と、その黄体カラー Doppler 画像に紐づけられている妊娠の成否を1組とすると、計1406組の黄体画像を用意できる。それらを、TensorFlowの学習による画像分類モデル作成と、そのモデルの正答率のテストに使用する。

#### 3.2.2 黄体画像(肉用牛)

前項と同様に、肉用牛の黄体を超音波検査によって撮影し、黄体カラー Doppler 画像を収集する。収集するのは、人工受精後14日前後経過時点での黄体カラー Doppler 画像である。Fig. 4は、実際に撮影された黄体カラー Doppler 画像である。Fig. 1の、乳用牛の黄体カラー Doppler 画像とは様式に違いがある。これは、黄体カラー Doppler 画像の撮影に使用された機器が、乳用牛の黄体と肉用牛の黄体の場合で違うためである。白黒で表されている扇型の部分に、黄体とその周辺部分が撮影されている。乳用牛のものと同様に、黄体周辺の血流の方向や面積も同時に写され、色と着色されている部分の面積で表されている。

人工受精後14日前後経過時点での肉用牛の黄体カラー Doppler 画像を収集する。同じ肉用牛において、それから26日前後経過時点、即ち人工受精後40日経過時点で、妊娠の成否を確認する。人工受精後14日前後経過時点の肉用牛の黄体カラー Doppler 画像と、人工受精後40日経過時点での妊娠の成否を1対1で紐づける。

全部で10頭の肉用牛において17回分の人工授精を行った。17回分の人工授精のうち、受胎(40日経過時点で妊娠していた)という結果が出たのが11回分、不受胎(40日経過時点で妊娠していなかった)という結果



が出たのが6回分である。撮影した黄体カラー Doppler 画像の総枚数は52枚であり、その内、受胎と紐づけられている黄体カラー Doppler 画像が33枚、不受胎と紐づけられている黄体カラー Doppler 画像が19枚存在する。

このように、黄体カラー Doppler 画像の撮影と妊娠の成否の確認を行い、52枚の黄体カラー Doppler 画像と、その黄体カラー Doppler 画像1枚ずつに妊娠の成否を紐づける。黄体カラー Doppler 画像1枚と、その黄体カラー Doppler 画像に紐づけられている妊娠の成否を1組とすると、計52組の黄体画像を用意できる。それらを、TensorFlow の学習によって作成された乳用牛の画像分類モデルの、肉用牛の黄体画像分類における正答率のテストに使用する。




Fig. 4: Example of color doppler ultrasonography image (beef cattle)

### 3.2.3 出力ラベル

人工受精後14日前後経過時点での黄体カラー Doppler 画像から画像分類モデルが出力する分類結果、つまり出力ラベルを2種類用意する。出力ラベルは、肉用牛と乳用牛で同じものを使用する。ラベルは以下の通りである。

ラベル1：不受胎(40日経過時点で妊娠していない)

ラベル2：受胎(40日経過時点で妊娠している)

画像分類モデルは、黄体カラー Doppler 画像から、必ずどちらかのラベルを出力する。

## 4. 画像分類モデルの作成実験の考察

### 4.1 実験1：全黄体画像による分類

前節で述べた黄体画像を使用し、TensorFlow の学習による画像分類モデルの作成と正答率の評価を行う。1406組の黄体画像のうち、100組をテスト用黄体画像とする。テスト用黄体画像の内訳は、受胎に分類される黄体画像が50組、不受胎に分類される黄体画像が50組である。テスト用黄体画像とは、作成済みの画像分類モデルに、学習用黄体画像以外の黄体画像を用い

た場合の正答率の評価に使用するための黄体画像である。1306組(受胎に分類される黄体画像が646組、不受胎に分類される黄体画像が660組)を、学習用黄体画像として TensorFlow の学習による画像分類モデルの作成に使用する。学習用黄体画像とは、黄体画像から妊娠の成否を予測する画像分類モデルを作成するための黄体画像である。

学習の際には、受胎に分類される黄体画像が50組、不受胎に分類される黄体画像が50組を、テスト用黄体画像として全黄体画像1406組から無作為に選ぶ。それ以外の1306組の黄体画像を学習用黄体画像として使用する。

学習用黄体画像1306組から無作為に100組を選び、それぞれどの黄体カラー Doppler 画像がどのラベルに分類されるのかを学習する。次に、残りの1206枚から無作為に100組を選び、それぞれどの黄体カラー Doppler 画像がどのラベルに分類されるのかを学習する。この流れを、1306組全てを学習に使用するまで繰り返し、それを1ステップとする。これを250ステップ繰り返す。

その後、テスト用黄体画像の全ての黄体カラー Doppler 画像を画像分類モデルが読み込み、ラベルを出力する。テスト用黄体画像のラベルと、画像分類モデルが出力したラベルを比較する。不受胎と受胎のラベルにおいて、それぞれのラベル全体で、テスト用黄体画像のラベルと画像分類モデルが出力したラベルが一致した割合を正答率として算出する。ここまでの流れを学習1回として、これを5回繰り返す。Table 1は、学習を5回行った後のそれぞれの正答率と、それらの平均である。

Table 1: Percentages of correct answer rates by labels after five trainings and their average (unit :%)

	1	2	3	4	5	Average
Non-conception	94	96	94	90	92	93.2
Conception	90	96	90	94	94	92.8

Table 1 に示される通り、乳用牛のランダムなテスト用黄体画像を分類させた場合、受胎、不受胎どちらも、平均して90%程度という結果となった。このことから、十分な学習用黄体画像を用いて画像分類モデルを作成した提案手法により、乳用牛の受胎/不受胎が十分な精度で分類できることが示された。



#### 4.2 実験2：判定対象個体以外の黄体画像による分類

前項と同様の黄体画像を使用し、TensorFlowの学習による画像分類モデルの作成と正答率の評価を行う。全55頭分の黄体画像のうち、1頭分をテスト用黄体画像とする。それ以外の54頭分を、学習用黄体画像としてTensorFlowの学習による画像分類モデルの作成に使用する。

学習用黄体画像から無作為に100組選び、それぞれの黄体カラー Doppler 画像がどのラベルに分類されるのかを学習する。次に、学習用黄体画像の残りから無作為に100組選び、それぞれの黄体カラー Doppler 画像がどのラベルに分類されるのかを学習する。この流れを、学習用黄体画像全てを学習に使用するまで繰り返し、それを1ステップとする。これを250ステップ繰り返す。

その後、テスト用黄体画像の全ての黄体カラー Doppler 画像を画像分類モデルが読み込み、ラベルを出力する。テスト用黄体画像のラベルと、画像分類モデルが出力したラベルを比較する。不受胎と受胎のラベルにおいて、それぞれのラベル全体で、テスト用黄体画像のラベルと画像分類モデルが出力したラベルが一致した割合を正答率として算出する。ここまでの流れを1回とする。これを、55頭全ての黄体画像がそれぞれ1回ずつテスト用黄体画像となるまで、55回繰り返す。Table 2は、全ての学習を終えた後のそれぞれの正答率の例である。55頭分の黄体画像のうち、5頭分の黄体画像が載っている。Fig. 5には、55頭分全黄体画像の結果の平均が載っている。乳用牛の個体の中には、受胎と分類された黄体カラー Doppler 画像が無いものや、不受胎と分類された黄体カラー Doppler 画像が無いものが存在する。その場合、黄体画像枚数を0とし、正答率を-(ハイフン)で表している。

Table 2: Correct answer rates when data of dairy cattle are used as test data each (number of images unit: sheet, correct answer rate unit: %)

Individual number	381	423	427	430	431
Number of images (conception)	0	34	0	0	0
Number of images (non-conception)	7	13	4	12	30
Collect answer rate (conception)	-	5.88	-	-	-
Collect answer rate (non-conception)	100	46.15	75	25	93.33




Fig. 5: Average of correct answer rates on all dairy cattle individual when data of dairy cattle are used as test data each (unit: %)

Fig. 5に示される通り、乳用牛を一頭ずつテスト用黄体画像として分類させた場合、受胎の正答率の平均が35%程度、不受胎の正答率の平均が55%程度という結果となった。これらの結果から、受胎の分類対象とは異なる牛の黄体画像のみを用いて画像分類モデルを作成した場合には、正しく分類できない場合がある事が示された。

#### 4.3 実験3：異なる品種の黄体画像による分類

乳用牛の黄体画像で学習した画像分類モデルに、肉用牛の黄体カラー Doppler 画像を二つのラベルに分類させる。全10頭の内、1頭分の肉用牛の黄体画像をテスト用黄体画像として使用する。テスト用黄体画像の黄体カラー Doppler 画像を画像分類モデルに読み込ませ、ラベルを出力させる。その後、テスト用黄体画像のラベルと画像分類モデルが出力したラベルを比較する。不受胎と受胎、それぞれのラベル全体で、どの程度の割合でテスト用黄体画像のラベルと画像分類モデルが出力したラベルが一致したかを正答率として算出する。ここまでの流れを1回とする。これを、10頭全ての黄体画像がそれぞれ1回ずつテスト用黄体画像となるまで、10回繰り返す。Table 3は、乳用牛の黄体画像を用いて学習を終えた後の、肉用牛の個体それぞれの正答率の例である。Fig. 6には、5頭分の黄体画像の結果の平均が載っている。肉用牛の個体によっては、受胎に紐づけられている黄体カラー Doppler 画像と不受胎に紐づけられている黄体カラー Doppler 画像どちらかの黄体カラー Doppler 画像が無いものもある。その場合、黄体カラー Doppler 画像枚数を0、正答率を-(ハイフン)で表している。

Table 3: Correct answer rates when data of beef cattle are used as test data each (number of images unit: sheet, correct answer rate unit: %)

Individual number	3252	6833	6877	8187	8189
Number of images (conception)	0	6	3	0	6
Number of images (non-conception)	4	0	3	6	0
Collect answer rate (conception)	-	100	100	-	100
Collect answer rate (non-conception)	0.5	-	0	0	-




Fig. 6 : Average of correct answer rates on all beef cattle individual when data of dairy cattle are used as training data (unit: %)

Fig. 6 に示される通り、乳用牛の黄体画像を用いた画像分類モデルを作成し、品種の異なる肉用牛を分類する場合、受胎の正答率が 100%、不受胎の正答率がほぼ 0%という結果となった。このような結果となった原因について考察する。

一つ目に、黄体カラー Doppler 画像の撮影機材やその用途の違いが挙げられる。本研究で使用した乳用牛の黄体カラー Doppler 画像は、オランダのメーカー製の、家畜用の機器で撮影されている。肉用牛の黄体カラー Doppler 画像は日立製の、人間の機器で撮影されている。乳用牛の黄体カラー Doppler 画像から、画像分類モデルが受胎と不受胎を分類するために抽出した特徴が、肉用牛の黄体カラー Doppler 画像にはそもそも写されていないということが考えられる。つまり、撮影機材やその用途の違いから、乳用牛の画像分類モデルでは、肉用牛の黄体カラー Doppler 画像からは受胎、不受胎を判断するための情報が得られず、分類ができないと思われる。黄体カラー Doppler 画像を撮影する際に、乳用牛と肉用牛で撮影機材を

統一する。そうすれば、乳用牛の黄体画像で作成した画像分類モデルで肉用牛の黄体カラー Doppler 画像を正確に分類できる可能性があると思われる。

二つ目に、撮影機材やその用途の違いを考えない場合、乳用牛と肉用牛では、妊娠の成否を分類できる特徴に違いがあると考えられる。乳用牛では、人工受精後 14 日前後における黄体周辺の血流の面積と、その後の妊娠の成否に相関がある<sup>1)</sup>。そのため、黄体周辺の血流面積が写っている黄体カラー Doppler 画像を使用すれば、将来の妊娠の成否が予測可能と思われる。肉用牛では、人工受精後 14 日前後における黄体周辺の血流の面積と、その後の妊娠の成否に相関が無い。よって、乳用牛においては、黄体周辺の血流の面積が写されている黄体カラー Doppler 画像を用いれば妊娠の成否が高精度で予測可能であると思われる。一方、肉用牛においては、前述の理由で、血流の面積でその後の妊娠の成否が予測不可能である。このことから、例えば、本研究で作成した乳用牛の画像分類モデルが、黄体周辺の血流の面積を確認して将来の妊娠の成否を分類していると仮定すると、肉用牛の黄体カラー Doppler 画像においては、その後の妊娠の成否が分類できないと思われる。

このように、乳用牛と肉用牛では、妊娠の成否を分類するための特徴に違いがある。さらに、今回は用いた黄体画像が少ないため、不確かな部分はあるが、品種が異なる牛の黄体画像を用いて作成した画像分類モデルでは、受胎/不受胎の判定は難しい可能性が高いと考えている。

#### 4.4 実験 4 : 1 頭のみ黄体画像による分類

4.1 節と 4.2 節の実験結果は、ランダムに取り出したテスト用黄体画像を分類させた場合の正答率は 90%程度で、一頭分をテスト用黄体画像として黄体カラー Doppler 画像を分類させた場合の不受胎の正答率は平均 55%程度であった。

これらの正答率の違いの原因について考察すると、4.1 節の実験では、テスト用黄体画像をランダムに取り出すことで、学習用黄体画像とテスト用黄体画像に、同じ個体の違う黄体画像がそれぞれ存在することになる。テスト用黄体画像に含まれる黄体画像と同じ個体の黄体画像が学習されることで、その個体における分類の基準も学習しているのではないかと考える。4.2 節の実験で、一頭分をテスト用黄体画像として分類させた場合に正答率が比較的低いのは、学習用黄体画像に同じ個体の黄体画像が無いために基準が学習できないということが理由の一つであると考えられる。

この考察について検証するため、本節では、乳用牛の全 55 頭分の黄体画像を個体毎に分ける。1 頭分の黄体画像において、1 組の黄体画像をテスト用黄体画像とし、それ以外の黄体画像全てを学習用黄体画像とす

る。学習用黄体画像を用いて画像分類モデルを作成し、テスト用黄体画像の黄体カラードブラー画像を読み込ませ、ラベルを出力させる。Table 2 の個体番号 381 で例を挙げると、この牛の個体の黄体画像数は 7 組であるので、1 組をテスト用黄体画像とし、残りの 6 組を学習用黄体画像とすることとなる。これを、その個体全ての黄体画像において行う。上記の例であれば、7 組の黄体画像全てが 1 回テスト用黄体画像となるように、テスト用黄体画像を入れ替えながら 7 回実験を行う。これを 53 頭分の個体について行う。総回数は総画像枚数と等しくなるので、1404 回となる。Fig. 7 には、1404 枚の黄体カラードブラー画像のラベル毎の分類結果の平均が載っている。




Fig. 7 : Average of correct answer rates on 1404 dairy cattle data when each data of dairy cattle individual are used as training data and test data (unit: %)

Fig. 7 に示される通り、1 頭分の黄体画像のみを用いて作成した画像分類モデルを用いることで、テスト用黄体画像をランダムに用いた実験 1 と同様に、平均して 90% 程度という結果となった。この結果から、ある牛の妊娠鑑定を行いたい場合、事前にその牛の受胎時と不受胎時の黄体画像さえ取得しておけば、妊娠鑑定を十分に行えると考える。この結果は、多数の乳用牛の黄体画像を用いる必要がないという意味で、提案手法が、小規模の農家にとっても役に立つ妊娠鑑定手法になりえると期待される。

## 5. おわりに

本研究では、牛の生産性向上のために、牛の早期(21 日以内)妊娠鑑定を目指した。早期妊娠鑑定の実現のために、ディープラーニングによる画像分類を手法として用いた。肉用牛・乳用牛において、人工受精後 14 日前後時点での黄体カラードブラー画像と、人工受精後 40 日時点での妊娠の成否という 2 種類の情報の組

を黄体画像として収集した。乳用牛の黄体画像を用いて、TensorFlow で画像分類モデルを作成した。作成した画像分類モデルを使用して、乳用牛・肉用牛の黄体画像における画像分類モデルの分類の正確さをテストした。乳用牛の黄体画像では、テスト用黄体画像をランダム、もしくは 1 頭毎としてテストを行った。肉用牛の黄体画像では、テスト用黄体画像を 1 頭毎としてテストを行った。

その結果、乳用牛において、テスト用黄体画像をランダムとしてテストを行った場合は一定の正確さを確認できた。一方で、乳用牛と肉用牛において、テスト用黄体画像を 1 頭毎としてテストを行った結果、正確さは比較的低かった。

乳用牛の黄体画像を取り扱った実験から、正答率の違いが起こる原因を考察した。学習用黄体画像に、分類する牛の個体の黄体画像と同じ個体の黄体画像が含まれているかどうかは正答率の違いの原因と考えた。この考察を検証するために、更に実験を行った。乳用牛のある個体の黄体画像について、1 組をテスト用黄体画像に、それ以外を学習用黄体画像として、これを 1 頭分の全黄体画像が 1 回ずつテスト用黄体画像となるように繰り返し、これを 53 頭の個体に対してテストを行った。その結果、一定の正確さを確認できた。妊娠鑑定を行いたい対象となる牛の黄体画像を用いて画像分類モデルを作成することで、十分に分類が可能となると考えられる。

本論文の結果から、提案手法を用いて牛の妊娠鑑定を行う場合は、妊娠鑑定を適用したい牛の個体の黄体画像を予め取得しておく必要がある事が示された。今後は、乳用牛と肉用牛という品種の異なる牛の黄体画像や、分類対象ではない牛の黄体画像しかない場合においても、妊娠鑑定を行える手法を検討する。

## 謝辞

本研究は、農林水産省からの委託事業（課題名：繁殖性の改善による家畜の生涯生産性向上技術の開発）として実施したものです。

## 参考文献

- 1) Tomomi Kanazawa, Motohide Seki, Keiki Ishiyama, Tomoaki Kubo, Yoshiyuki Kaneda, Minoru Sakaguchi, Yoshiaki Izaike, Toru Takahashi : Pregnancy prediction on the day of embryo transfer(Day 7) and day 14 by measuring luteal blood flow in dairy cows, *Theriogenology*, 86-6, 1436/1444(2016)
- 2) Hitomi Yoshino, Noriyuki Toji, Kouya Sasaki, Katsuo Koshi, Norio Yamagishi, Toru Takahashi, Toshina Ishiguro-Oonuma, Hideo Matsuda, Tadayuki Yamanouchi, Yutaka Hashiyada, Kei Imai, Yoshiaki Izaike, Keiichiro Kizaki, Kazuyoshi Hashizume: A predictive threshold value for the diagnosis of early pregnancy in cows using interferon-stimulated genes in

granulocytes, *Theriogenology*, 107, 188/193(2018)

- 3) Martín Abadi, Ashish Agarwal, Paul Barham, Eugene Brevdo, Zhifeng Chen, Craig Citro, Greg S. Corrado, Andy Davis, Jeffrey Dean, Matthieu Devin, Sanjay Ghemawat, Ian Goodfellow, Andrew Harp, Geoffrey Irving, Michael Isard, Rafal Jozefowicz, Yangqing Jia, Lukasz Kaiser, Manjunath Kudlur, Josh Levenberg, Dan Mané, Mike Schuster, Rajat Monga, Sherry Moore, Derek Murray, Chris Olah, Jonathon Shlens, Benoit Steiner, Ilya Sutskever, Kunal Talwar, Paul Tucker, Vincent Vanhoucke, Vijay Vasudevan, Fernanda Viégas, Oriol Vinyals, Pete Warden, Martin Wattenberg, Martin Wicke, Yuan Yu, and Xiaoqiang Zheng. TensorFlow: Large-scale machine learning on heterogeneous systems, 2015. Software available from tensorflow.org.
- 4) do, Zhifeng Chen, Craig Citro, Greg S. Corrado, Andy Davis, B. B. Le Cun, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard, L. D. Jackel, Handwritten digit recognition with a back-propagation network: Proceedings of the Advances in Neural Information Processing Systems (NIPS), 396/404(1989)
- 5) Jiuxiang Gu, Zhenhua Wang, Jason Kuen, Lianyang Ma, Amir Shahroudy, Bing Shuai, Ting Liu, Xingxing Wang, Gang Wang, Jianfei Cai, Tsuhan Chen: Recent advances in convolutional neural networks, *Pattern Recognition*, 77, 354/377(2018)
- 6) Yann LeCun, Yoshua Bengio, Geoffrey Hinton: Deep learning, *Nature*, 521, 436/444(2015)
- 7) Rosenblatt F: The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65, 386/408(1958)
- 8) Rumelhart David E., Hinton Geoffrey E, Williams Ronald J: Learning Internal representations by Error Propagation, *Parallel distributed processing: explorations in the micro-structure of cognition*, 1, 318/362(1986)
- 9) Motozumi Matsui, Akio Miyamoto: Evaluation of ovarian blood flow by colour Doppler ultrasound: Practical use for reproductive management in the cow, *The Veterinary Journal*, 181, 232/240(2009)
- 10) H Bollwein, J Maierl, R Mayer, R Stolla: Transrectal color Doppler sonography of the A. uterine in cyclic mares, *theriogenology*, 49, 1483/1488(1998)



# 深層畳込み生成敵対ネットワーク DCGAN で生成した旋律を人はいかに感じるか

高木雄太 橘完太 (工学院大学)

## How human feel the melodies generated with deep convolutional generative adversarial networks

Yuta Takagi and Kanta Tachibana (Kogakuin University)

**Abstract**— Research on deep convolutional generative network (DCGAN) is popular as a method to generate fake patterns similar to the input patterns. In this study, DCGAN was learned for each work based on the main melody (17 to 20 pieces for each work) 4 works of the same genre. 4 fake melodies were generated for each work. Have the subject listen to the generated 16 songs, asked to the SD method to evaluate the 4-adjective pairs in 5 levels, and examine how people feel.

**Key Words:** DCGAN, generation of melodies, human impression

### 1.はじめに

人は音楽によって心を動かされることが多々起こりうる。涙を流したり、興奮したり、笑顔になったりなど、人々の感情を動かすことが可能なほどの力を持っている。

もし、そのような音楽を機械が作り出すことが出来たとしたら、機械も人のように人の心を動かすことが可能になるのではないかと考えた。実際に機械学習によって音楽を生成する研究が近年行われており、楽譜という画像データを基に楽譜を生成したり 5)、深層学習によって音を生成したり 1)、機械学習の1種である DCGAN を用いてループ音源を生成したり 2)するなどの研究がその例となっている。

また、音楽が心に響くとはどういったことなのかを知るため、被験者に音楽の印象を評価してもらう。先行研究として、規則的に生成した音楽に対して快・不快を評価する研究があり 4)、本研究でもその研究を参考に人に評価してもらう項目を作成してそれを評価してもらう SD 法を用いることにした。音楽に対する評価項目として相応しいものを決めるため、杉原らの研究を参考にし、被験者に評価してもらう 4 項目を決定した 3)。これは、杉原らが曲の感性を比較するのに用いた 4 項目を使用した。

本研究では、実際に DCGAN で音楽を生成し、被験者 10 名に評価を行ってもらった。

### 2.GANの構造

#### 2.1 GAN とは

パターンである訓練データを学習し、パターンを表現する空間内の訓練データの分布と生成データの分布が一致するような新たなデータを生成するモデルを生成モデルと呼ぶ。GAN はこの生成モデルの一種である。

GAN は Generator と Discriminator の 2 つの学習器・ニューラルネットワークを使用する。Generator は訓練データを教師データとして訓練データと似た新データを生成するよう学習する役割を持ち、Discriminator はデータが訓練データからきたものか新たに生成されたデータかを判別する役割を持

つ。Generator と Discriminator の 2 つが交互に学習を繰り返すことによって、より訓練データと似たデータを生成するという構造である。Fig. 1 の  $X_{\text{real}}$  は学習に用いる訓練データを示している。 $Z$  は生成源の確率変数であり、多次元の一様分布や正規分布が用いられる。GAN では訓練データ、Generator の出力、および、Discriminator の入力として画像が用いられることが一般的である。

#### 3.2 DCGAN

本研究では、Deep Convolutional GAN (以下 DCGAN) を使用する。DCGAN の目的関数 (loss 関数) を式に示す

$$\min_G \max_D V(D, G) = E_{x \sim p_{\text{train}}(x)} [\log D(x)] + E_{z \sim p_z(x)} [\log(1 - D(G(z)))]$$

写像  $G: \mathbb{R}^M \rightarrow \mathbb{R}^N$  は Generator を、写像  $D: \mathbb{R}^N \rightarrow [0, 1]$  は Discriminator を示す。 $p_{\text{train}}(x)$ ,  $x \in \mathbb{R}^N$  は訓練データの確率分布を、 $p_z(x)$ ,  $z \in \mathbb{R}^M$  は生成源の確率分布を表す。 $G$  は生成源の実現値  $z$  を入力してパターン  $x$  を生成し、 $D(x)$  はパターンが訓練データである確率を表している。 $D$  は訓練データと生成データを正しく見分ける確率を最大化しようとし、 $G$  は訓練データとより似たデータを生成しようとするため、 $\log(1 - D(G(x)))$  を最小化しようとする。 $D$  の学習が進むと、訓練データに対して  $D(x)$  が大きくなり、 $\log D(x)$  が大きくなる。また、fake データに対する判別結果が正答だった場合は  $D(G(z))$  が小さくなり、 $\log(1 - D(G(z)))$  は大きくなる。 $G$  の学習が進み、 $G$  が訓練データに似ているものを生成可能となると  $D$  による分類が難しくなるため、fake データに対する  $D(G(z))$  が大きくなり、 $\log(1 - D(G(z)))$  は小さくなる。






Fig 1 : DCGAN のネットワーク構造<sup>1</sup>

DCGAN は乱数で与えられたベクトルから画像を生成し、G の学習によって生成する画像 (Fig. 2 の Xfake) を徐々に変化させていき、D の真偽判定の学習によって真として出力する画像も変化していく構造となっている。

DCGAN の実装には、Github で公開されているプログラム<sup>2</sup>を使用し、設定はデフォルトのまま使用した。エポック数は 15 とした。

#### 4.使用データ

訓練データの基のmidiデータは、東方ピアノEasyモード<sup>3</sup>を使用した。音楽ソフトを使用し、ゲームミュージック 4 作品計72曲 (作品A : 17曲, 作品B:20曲, 作品C:18曲, 作品D : 17曲) のサビなどその曲の特徴的な個所の 4 小節分の主旋律を抜き出した。Fig2に抜き出した主旋律の例を示す。




Fig 2 : 音楽ソフトで抜き出した主旋律

抜き出した 4 小節の主旋律の各音を 16 分音符の長さに変換する。画像編集ソフトを用いて 64 × 64 ピクセルの二値画像として作成する。Fig 3に主旋律を変換した二値画像の例を示す。これを計72曲の特徴的な部分全てについて行い、作品ご

とに分けて訓練データA, B, C, Dとして使用した。主旋律の音程はB2からC6までの範囲が用いられ、下の12ピクセルと上の16ピクセルは訓練データとして用いた72枚の画像ではすべて白(255)であった。




Fig 3 : 二値画像に編集した主旋律の例

二値画像を訓練データとしてGeneratorおよびDiscriminatorを学習させて画像データを生成する。学習の終了条件はエポックを15回行った時とした。この際、Zには100次元の一様分布を用いる。

学習後のDCGANから生成された画像は各画素に{0,255}以外の値を含むため、閾値を220とした二値化プログラムを使用し、二値画像に変換する。学習済みのGANから生成された画像の例をFig5に示す。二値化処理を行った画像の例をFig6に示す。

生成した主旋律の画像の通りに音楽ソフトに入力し、入力したものを1つの生成された曲として使用する。これを4作品それぞれに4曲ずつ生成し、実験に使用する生成データとして扱う。

1~4番の曲は作品Aから、5~8番の曲は作品Bから、9~12番の曲は作品Cから、13~16番の曲は作品Dから生成した。

それぞれの作品から曲を生成するにはそれぞれGAN:A, GAN:B, GAN:C, GAN:Dを使用した



Fig 4 : 学習済み GAN で生成された画像

<sup>1</sup> <http://mizti.hatenablog.com/entry/2016/12/10/224426>

<sup>2</sup> <https://github.com/carpedm20/DCGAN-tensorflow>

<sup>3</sup> <http://easypianoscore.jp/>



Fig 5 : Fig4 に二値化処理を施した画像

## 5.実験手法と結果

### 5.1 分散での解析

生成された音楽を作品 A,B,C,D の 4 つずつの計 16 曲の音楽を聴いてもらい,SD法を用いて5段階で回答してもらう。その際に使用する形容詞対は杉原らの論文 4)に基づいて,「ありきたりな—新鮮な」,「賑やかな—静かな」,「単調な—メリハリのある」,「重厚な—軽快な」の 4 つと設定し 1 から 5 までの 5 段階評価をしてもらった。

また,その曲を過去に聴いたことがあるか否かも被験者に回答してもらう。被験者の数は 10 名で行った。

まず,SD法で得た 4 次元データに対して分散を計算し,個人差,作品内の曲の間,作品間の 3 つの基準についてデータのばらつきを調べた。Table1 に被験者の回答をまとめる。まず,1 から 5 までの評点の中間が零となるように,各回答の値から 3 を減じた。1 行目には全被験者の 16 曲すべてに対する平均を示す。2~5 行目には,作品ごと 4 曲に対する全被験者の平均ベクトルを示す。6~9 行目には,曲ごとに対する被験者の平均ベクトルを示す。

Table 1: 被験者回答の平均ベクトル

		「ありきたりな—新鮮な」	「賑やかな—静かな」	「単調な—メリハリのある」	「重厚な—軽快な」
全	Z	0.043	0.087	0.218	0.350
作品ごと	A	-0.17	-0.05	0.30	0.85
	B	0.20	0.02	-0.40	0.17
	C	-0.05	0.32	0.62	0.00
	D	0.20	0.10	0.35	0.37

曲ごと	a1	-0.9	0.3	0.2	0.9
	a2	-0.5	0.7	0.4	0.4
	a3	0.5	-0.2	0.2	0.6
	a4	0.2	-1	0.4	1.5

これらの平均ベクトルから分散を計算した。作品間の分散:0.29,同じ作品内の曲間の分散は作品A:0.89,B:1.08,C:0.84,D:1.00,であった。同じ曲の個人差による分散は,16 曲の最小値 3.08、中央値 4.98、平均値 4.77、最大値 6.68 であった。分散計算の結果からは,個人差がとても大きいことがわかった。

以降では,個人差の影響を受けないよう,同じ個人が曲の違いによりどれだけ評価を変えたかに注目して評価する。

### 5.2 コサイン類似度計算での解析

被験者の回答した数値にコサイン類似度計算を行う。ある曲に対する回答をベクトル A とし,その被験者の他の曲に対する回答をベクトル B としたときに,

$$\cos(\vec{A}, \vec{B}) = \frac{\sum_{i=1}^4 A_i B_i}{\sqrt{\sum_{i=1}^4 A_i^2} \cdot \sqrt{\sum_{i=1}^4 B_i^2}}$$

を計算する

### 5.3 コサイン類似度計算での結果

Table 2 に例として作品 A をもとに学習した DCGAN で生成した 4 曲に対する被験者 1 人目の回答結果を示す。被験者 10 名の回答結果を見ると,作品 A 内の 4 曲,作品 C 内の 4 曲の類似度が高かった。Table 3 と 5 に作品 A 内と,作品 C 内での 10 名の平均値を示す。

Table 2:被験者の回答 (作品 A)

	「ありきたりな—新鮮な」	「賑やかな—静かな」	「単調な—メリハリのある」	「重厚な—軽快な」
a1	-2	-1	-1	-1
a2	0	2	-1	-2
a3	1	2	-1	-2
a4	0	-2	-2	2

**Table 3 : コサイン類似度数値の平均 (作品 A)**

	a1	a2	a3	a4
a1	1	0.346	0.082	0.266
a2	0.346	1	0.127	0.028
a3	0.082	0.127	1	0.408
a4	0.266	0.028	0.408	1

作品 A 内では a1 と a2, a3 と a4 がそれぞれ比較的似ていると評価できる. この 2 つの組み合わせについて、10 名の平均、中間値、最小値、最大値を Table 4 に示す.

**Table 4 : 1-2, 3-4 の平均値, 中間値, 最大値, 最小値**

	平均値	中央値	最小値	最大値
a1-a2	0.346	0.374	-0.288	0.816
a3-a4	0.408	0.617	-0.547	1

**Table 5 : コサイン類似度数値の平均 (作品 C)**

	c9	c10	c11	c12
c9	1	-0.0638	0.4842	0.0394
c10	-0.0638	1	-0.0537	0.4994
c11	0.4842	-0.0537	1	0.2274
c12	0.0394	0.4994	0.2274	1

行と列は c1 から c4 までそれぞれ順番の曲に対する数値の平均が入力されている. Table 3 と同様に () 中の数字は曲番号を表している.

作品 C 内では c9 と c11, c10 と c12 が比較的似ていると評価されている. この 2 つの組み合わせの平均、中間値、最小値、最大値を Table 6 に示す.

**Table 6 : 1-3, 2-4 の平均値, 中間値, 最大値, 最小値**

	平均値	中央値	最小値	最大値
C9-c11	0.484	0.635	-0.645	0.942
C10-c12	0.499	0.651	-0.566	1

作品内に限らずに 16 曲全てを比較したところ、作品 A と C はそれぞれ似た曲が多いという結果が出た. また、最も似ていると評価された曲同士は a4 番と d16 番であり、最も似ていないと評価された曲同士は b8 番と c9 番であった. この 2 つの組み合わせの平均、中間値、最小値、最大値を Table 7 に示す.

Fig 6 に a4 の楽譜を示す. Fig 7 に d16 の楽譜を示す. Fig 8 に b8 の楽譜を示す. Fig 9 に c9 の楽譜を示す. また、c9 のみ二重化を行った結果、一つの列に 2 つの黒(0)が出力されたため、16 曲の中で唯一主旋律が 2 段 (和音) となっている.

**Table 7 : 4-16, 8-9 の平均値, 中間値, 最大値, 最小値**

	平均値	中央値	最小値	最大値
a4-d16	0.553	0.547	0	1
b8-c9	-0.493	-0.670	-0.956	0.478



**Fig 6 : a4 の楽譜**



**Fig 7 : d16 の楽譜**



**Fig 8 : b8 の楽譜**



**Fig 9 : c9 の楽譜**

## 6. 結論

DCGAN によって音楽を生成し、それを SD 法によって人に評価してもらった. その評価結果を分散とコサイン類似度計算の二つの方法で解析を行った.

その結果、分散による解析では個人差が大きいことが明らかになった. そこで個人が違う曲に対しては印象の違いに注目してコサイン類似度を計算した.

コサイン類似度計算の解析では、作品 A を基に生成した 4 曲と作品 C をもとに生成した 4 曲はそれぞれ似た曲が多かった。また、作品 C の内部ではコサイン類似度を見た限り、9 曲目と 11 曲目、10 曲目と 12 曲目がそれぞれ似ている曲となっている。

作品内に限定しなければ 4 曲目と 16 曲目が最も似ている曲となり、8 曲目と 9 曲目が最も似ていない曲となった。

## **8.参考文献.**

- 1)土井 樹,小島 大樹,池上 高志,「深層学習を用いた音の生成モデル」,日本物理学会 2016 年秋季大会講演概要集 Vol. 71, No.2, 2746 (2016)
- 2) 細川 皓平、川村 秀憲「DCGAN によるループ音源の学習と生成」人工知能学会知識ベースシステム研究会, 110, pp.6-11 (2017)
- 3)杉原 太郎,森本 一成,黒川 隆夫「SD 法を通してみた音楽に対する感性の基本特性」電子情報通信技術研究報告、101 巻、227 号(HIP2001 7-15), pp. 57-63 (2017)
- 4) 梅村 祥之,「規則的に生成した 4 音符からなる楽曲を用いた楽曲の心地よさに関する客観評価指標」, 情報処理学会研究報告, Vol. 2014-104, No. 17, pp. 1-7 (2014)
- 5) 平田 圭二,伊藤 貴之,北原 覚,今井 慎太郎,持橋 大地「人工知能は作曲家/演奏家になれるか」, 2017 年度人工知能学会全国大会 (第 31 回), pp. 1-2 (2017)

# 欠損値のない学習用データが利用可能な場合における 欠損値に対してロバストな学習法

○福島 卓弥 長谷川 拓 中島 智晴 (大阪府立大学)

## Robust Learning Methods against Missing Values in the Case where a Training Data Set without Missing Values is Available

\*Takuya Fukushima, Taku Hasegawa, and Tomoharu Nakashima  
(Osaka Prefecture University)

**Abstract**— This paper presents how to tackle with missing data in the prediction by a trained machine learning model. We assume that the training dataset is complete without any missing values, however, there exist missing values in the feature values during the course of prediction. Thus, the task in this paper is investigate how to train a machine learning model that robustly predict for incomplete input information with a minimum error. We propose an intentional substitution during training a model where a feature value is replaced with a certain value with a specified probability. After giving some theoretical analysis on the optimal substitution value for an ideal situation, a series of computational experiments are conducted in order to evaluate neural networks that are trained with the proposed method for synthetic tasks.

**Key Words:** machine learning, incomplete data, regression, neural network

### 1 はじめに

多くの機械学習手法では、データに欠損値がないことが前提となっている。構築されるモデルの精度が十分になるほどの量と質が学習用データに含まれていることが理想である。欠損値がないことも理想的な状況である。しかし、このような状況は実問題で常に起こらない。例えば医療診断では、測定機器のエラーや故障により値が得られない可能性があり、このような場合、医師は測定値がないまま適切な診断をする必要に迫られる。

欠損値を扱う手法はこれまでに色々と提案されている<sup>1)</sup>。一つの方法は、欠損値に対して代表値を使用する代入法と呼ばれるものである(例えば、ゼロ、平均、学習用データから作られた推定モデルの出力値)。他にも、欠損する特徴量自体を使用せずに欠落させて学習モデルを構築する方法もある。

統計的モデリングを用いて適切なモデルパラメータを特定し、そのモデルを用いて欠損値を推定する方法も提案されている<sup>2)3)</sup>。また、欠損値を扱う方法は例えば、多重代入法<sup>4)5)</sup>や最尤推定法<sup>6)</sup>として議論されている。

Volker ら<sup>7)</sup>はニューラルネットワークの学習時に欠損値を取り込む方法を提案し、代入法のリスクが提言されている。Alan<sup>8)</sup>は、欠損値の取扱いに対して最適な方策を講じなければ、推定に偏りが生じ、統計的モデルの利点をうまく活かせずに不適切な結論を出しうることを指摘し、代入法に関する議論を行なっている。

上で紹介した研究では、学習用データとテストデータ(未知データ)ともに欠損値があることが仮定されている。本研究では、学習用データには欠損値がなく、未知データには欠損値がある場合を考えることにする。このような状況は、実世界でも起こりうる。例えば、医療の研修中はメンターからの教示や教本からの知識獲得により、学習のための十分な情報量が利用可能であるが、実際の緊急を要する場面では、学習時ほどの情

報が得られないまま適切な判断をしなければならない。また、スポーツの場面においても、トレーニング中や練習試合では、コーチからのアドバイスや振り返りを行うことにより学習に十分な情報量が利用可能であるが、試合では、練習時よりも少ない情報から判断を迫られ、学習時に利用できていた情報が獲得できないことがある。また、本研究では、どの特徴量に欠損が発生するのかについての事前情報があるものとする。

### 2 欠損値に対するロバスト予測

本章では、本研究で取り扱う欠損時を含む入力情報からの予測問題を述べ、定式化する。この問題に対して、モデル学習における意図的代入法を提案する。また、理論的な解析を行い、意図的代入法における最適性を議論する。

#### 2.1 問題の定義

本研究では、モデル学習時には欠損値が含まれない完全な学習用データを用いることができるが、学習されたモデルを使って未知データに対する予測を行う際には、その未知データには欠損値が含まれる可能性があるという状況を仮定する。また、未知データに対する予測時にどの特徴量で欠損が発生しうるかをあらかじめ知っているものとする。この仮定により、欠損値に対する戦略を立ててモデルを学習することができる。

いま、 $N_{training}$  個の  $n$  次元ベクトルとその出力値のペアからなる学習用データを  $D_{training} = \{\mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{in}), y_i | i = 1, 2, \dots, N_{training}\}$  とする。また、出力値が不明な未知データを  $\mathbf{x}_i = (x_1, x_2, \dots, x_n)$  とする。今後、欠損値に対して記号  $?$  を用いて表記することにすなわ、欠損値は値がわからない、入手不可能などの理由により「値がない」ことを表し、値がゼロであることは別であることに注意する。

上記の仮定と表記を用いて、本研究におけるモデル学習は、以下のように  $D_{train}$  から  $f(\mathbf{x})$  を求める問題になる。



$$f^*(\mathbf{x}) = \arg \min_{D_{test}} \sum \{f(\mathbf{x}_i) - y_i\}^2 \quad (1)$$

本研究で取り扱う欠損値の取り扱いと他の欠損値の取り扱い研究との主な違いは、学習用データ  $D_{train}$  には欠損値がなく、未知データには欠損値が発生する可能性があるという点である。本研究では、欠損値の取り扱い方法として、意図的代入法を提案する。次節で意図的代入法を説明する。

## 2.2 意図的代入法によるモデル学習

前節では、本研究で取り扱う問題を説明した。すなわち、欠損値のない完全な学習用データが利用可能な時に、欠損値をうまく取り扱うことができる機械学習モデルの構築である。式 (1) における  $f^*(\mathbf{x})$  を求めるために、学習用データを意図的代入法により修正する。意図的代入を行う際には、学習用データに欠損がなく、値が利用可能であったとしてもそれを使用せずに強制的に値を置換する。また、意図的代入は常に行うものではなく、あらかじめ決められた確率に従って行うものとする。以下に、意図的代入法の手続きを示す。以下の手続きでは、ある一つの入力ベクトルに意図的代入を実行する場合は想定されており、どの特徴量で欠損が発生するかがあらかじめモデル学習の時点でわかっているものとする。この手続きをミニバッチ方式に拡張してモデル学習に適用するには、手続きをバッチサイズだけ繰り返せばよい。

Step 1: 学習用データ  $D_{train}$  から入力ベクトルを一つ抽出する。

Step 2: あらかじめ決められた確率に従って、欠損すると思われる特徴量のある値と置換する。

Step 3: 修正された入力ベクトルと教師信号を用いてモデルを学習する

提案する意図的代入法では、二つのことに留意しなければならない。一つは、どのような値を代入に用いるかの決定であり、もう一つは意図的に代入をする確率の設定である。以下では、まず、これらの二つの問いに対する理論的考察への足がかりとして、欠損があるデータの学習モデルの定式化を行い、誤差の期待値を理論的に解析することで最適な方策について検討する。次に、理論的な解析結果を踏まえ、数値実験を行うことにより代入値と代入確率についてさらに議論を進める。

## 2.3 定式化

本節ではまず、欠損があるデータを学習するモデルの定式化を行う。次に、誤差の期待値を理論的に解析することにより、欠損値に対する代入値について議論を進める。この理論的考察により、ある条件の下では、欠損値の取り扱いとして直感的でよく知られた単純な代入法ではモデルの精度が高くないことを示す。また、上記の条件下における理論的に最適な代入値を導出する。

本論文で取り扱う欠損値の取り扱い問題の設定を統計的に述べる。学習用データにおける入力および未知データは  $n$  次元実数ベクトルとする。  $n$  個の特徴量を

$n$  次元実数ベクトル  $\vec{X} = (X_1, X_2, \dots, X_n)$  と表すことにする。また、各特徴量に欠損があるかないかを表すために  $n$  次元確率変数  $\vec{R} = (R_1, R_2, \dots, R_n)$  を以下のように定義する。

$$R_i = \begin{cases} 1, & \text{if } x_i \text{ is observed,} \\ 0, & \text{otherwise (i.e., } x_i \text{ is missing).} \end{cases} \quad (2)$$

このとき、得られる新しい確率変数を

$$X'_i = \begin{cases} X_i & (\text{observed}) \\ ? & (\text{missing}) \end{cases} \quad (3)$$

とし、 $X, R \xrightarrow{\phi} X'$  とすると  $\phi$  は全単射となる。このように  $(X_1, \dots, X_n, R_1, \dots, R_n)$  の同時分布として欠損値の取り扱い問題を捉えたと、同時確率密度関数  $p(\mathbf{x}, \mathbf{r})$  を

$$p(\mathbf{x}, \mathbf{r}) = p(\mathbf{x}|\mathbf{r})p(\mathbf{r}) = p(\mathbf{r}|\mathbf{x})p(\mathbf{x}) \quad (4)$$

とモデル化できる。ここで  $p(\mathbf{x}) = p(x_1, \dots, x_n)$  は  $X_1, \dots, X_n$  の周辺確率密度関数、 $p(\mathbf{r}|\mathbf{x})$  は  $X = \mathbf{x}$  のとき、各次元の要素が観測されたかどうかを表す確率関数である。

続いて、実際に欠損した場合に、欠損した次元に対してある値を代入する（ある値で置き換える）操作について定義する。欠損が観測された任意の入力ベクトル  $\forall \mathbf{x}' \in \{x'_1, \dots, x'_n | x'_i \in \mathbb{R} \cup \{?\}\} = \mathbb{R}_n^?$  に対して、写像  $\psi: \mathbb{R}_n^? \rightarrow \mathbb{R}^n$  を定めると、ある値を代入後の入力ベクトルは  $\mathbf{x}^* = \psi(\mathbf{x}') = \psi(\phi(\mathbf{x}, \mathbf{r})) = (\psi^r(\mathbf{x}))$  と表現できる。

さらに、 $\psi^r(\mathbf{x}) = \psi_1^r \times \dots \times \psi_n^r(\mathbf{x}) = \psi_1^r(\mathbf{x}), \dots, \psi_n^r(\mathbf{x})$  と分解すると、

$$\psi_i(\phi(\mathbf{x}, \mathbf{r})) = \begin{cases} x_i & (r_i = 1) \\ \psi_i^r(\mathbf{x}_{\text{obs}}) & (r_i = 0) \end{cases} \quad (5)$$

と書ける。ただし  $\mathbf{x}_{\text{obs}}$  は観測できた次元のみからなるベクトルとする。

次に、2.1 節で述べた問題に対する近似モデルとその誤差関数について述べる。目標とする真の関数を  $f$ 、予測モデルを  $g$  とする。また簡単のため、 $f: \mathbb{R}^n \rightarrow \mathbb{R}$ 、 $g: \mathbb{R}^n \rightarrow \mathbb{R}$  であるとする。ある点  $\mathbf{x}$  における  $f$  と  $g$  の距離（誤差）を  $\delta(f(\mathbf{x}), g(\mathbf{x}))$  とし、 $\mathbf{r}$  の実現値の集合を  $S = \{s_1, \dots, s_n | \forall i \in \mathbb{N}, s_i \in \{0, 1\}\}$  とおく。このとき、 $f$  と  $g$  の距離  $\delta$  の期待値は

$$\begin{aligned} \mathbb{E} [\delta(f, g)] &= \sum_{\mathbf{s} \in S} \int \dots \int_{D_X} p(\mathbf{x}, \mathbf{r} = \mathbf{s}) dX \quad (6) \\ &= \int \dots \int_{D_X} p_1(\mathbf{x}) d(f(\mathbf{x}), g(\mathbf{x})) dX \\ &+ \sum_{\mathbf{s} \in S \setminus \{1\}} \int \dots \int_{D_X} p_s(\mathbf{x}) d(f(\mathbf{x}), g(\psi^s(\mathbf{x}))) dX \quad (7) \end{aligned}$$

と書ける。ただし  $p_1(\mathbf{x}) = p(\mathbf{x}, \mathbf{r} = \mathbf{1})$ 、 $p_s(\mathbf{x}) = p(\mathbf{x}, \mathbf{r} = \mathbf{s})$  と置いた。以後、特に断りが無い限り、 $\int \dots \int_{D_X} = \int_{D_X}$  と簡略化する。

式 (7) において、第 1 項は欠損がない場合の誤差の期待値であり、第 2 項以降は欠損を考慮した期待値である。誤差を  $\delta(f, g) = \{f - g\}^2$  と仮定すると、

$$\mathbb{E}[\delta(f, g)] = \int_{D_X} p_1(\mathbf{x}) \{f(\mathbf{x}) - g(\mathbf{x})\}^2 dX + \sum_{s \in S \setminus \{1\}} \int_{D_X} p_s(\mathbf{x}) \{f(\mathbf{x}) - g(\psi^s(\mathbf{x}))\}^2 dX \quad (8)$$

ここで、とある  $s$  の項に着目する。表記を簡単にするため、 $s$  は  $s_1 = s_2 = \dots = s_k = 1, s_{k+1} = s_{k+2} = \dots = s_n = 0$  であるとする。この簡略化により一般性を失うことはなく、これを満たさない全ての場合においても同様の議論になる。 $X_{\text{obs}} = X_1, X_2, \dots, X_k, X_{\text{mis}} = X_{k+1}, X_{k+2}, \dots, X_n$  とすると式 (8) の  $r = s$  となる項は 以下のように書くことができる。

$$\begin{aligned} & \int_{D_X} p_s(\mathbf{x}) \{f(\mathbf{x}) - g(\psi^s(\mathbf{x}))\}^2 dX \\ = & \int_{D_X} p_s(\mathbf{x}) f^2(\mathbf{x}) dX \\ & - 2 \int_{D_{X_{\text{obs}}} \times D_{X_{\text{mis}}}} p_s(\mathbf{x}) f(\mathbf{x}) \cdot \\ & g(\mathbf{x}_{\text{obs}}, \psi'_{k+1}(\mathbf{x}_{\text{obs}}), \dots, \psi'_n(\mathbf{x}_{\text{obs}})) dX_{\text{mis}} dX_{\text{obs}} \\ & + \int_{D_{X_{\text{obs}}} \times D_{X_{\text{mis}}}} p_s(\mathbf{x}) \cdot \\ & g^2(\mathbf{x}_{\text{obs}}, \psi'_{k+1}(\mathbf{x}_{\text{obs}}), \dots, \psi'_n(\mathbf{x}_{\text{obs}})) dX_{\text{mis}} dX_{\text{obs}} \\ = & \int_{D_X} p_s(\mathbf{x}) f^2(\mathbf{x}) dX \\ & - 2 \int_{D_{X_{\text{obs}}}} g(\mathbf{x}_{\text{obs}}, \psi'_{k+1}(\mathbf{x}_{\text{obs}}), \dots, \psi'_n(\mathbf{x}_{\text{obs}})) \\ & \cdot \left[ \int_{D_{X_{\text{mis}}}} p_s(\mathbf{x}) f(\mathbf{x}) dX_{\text{mis}} \right] dX_{\text{obs}} \\ & + \int_{D_{X_{\text{obs}}}} g^2(\mathbf{x}_{\text{obs}}, \psi'_{k+1}(\mathbf{x}_{\text{obs}}), \dots, \psi'_n(\mathbf{x}_{\text{obs}})) \\ & \cdot \left[ \int_{D_{X_{\text{mis}}}} p_s(\mathbf{x}) dX_{\text{mis}} \right] dX_{\text{obs}} \quad (9) \end{aligned}$$

ここで、式 (9) において  $\int_{D_{X_{\text{mis}}}} p_s(\mathbf{x}) dX_{\text{mis}} = p_s(\mathbf{x}_{\text{obs}}) \cdot \int_{D_{X_{\text{mis}}}} p_s(\mathbf{x}_{\text{mis}} | \mathbf{x}_{\text{obs}}) dX_{\text{mis}}$  であり、これは  $X_{\text{mis}}$  で周辺化した  $\mathbf{x}_{\text{obs}}$  の周辺分布である。また、

$$\begin{aligned} & \int_{D_{X_{\text{mis}}}} p_s(\mathbf{x}) f(\mathbf{x}) dX_{\text{mis}} \\ = & p_s(\mathbf{x}_{\text{obs}}) \cdot \int_{D_{X_{\text{mis}}}} p_s(\mathbf{x}_{\text{mis}} | \mathbf{x}_{\text{obs}}) f(\mathbf{x}) dX_{\text{mis}} \quad (10) \\ = & p_s(\mathbf{x}_{\text{obs}}) \cdot \mathbb{E}_{X_{\text{mis}}} [f(\mathbf{x})] \end{aligned}$$

と変形でき、これは上の周辺確率に関する期待値である。以下では  $\mathbb{E}_{X_{\text{mis}}} [f(\mathbf{x})] = e_s(\mathbf{x}_{\text{obs}})$  と表記する。

上記を踏まえて、 $g'(\mathbf{x}_{\text{obs}}) = g(\mathbf{x}_{\text{obs}}, \psi'_{k+1}(\mathbf{x}_{\text{obs}}),$

$\dots, \psi'_n(\mathbf{x}_{\text{obs}}))$  とおくと、

$$\begin{aligned} & \int_{D_X} p_s(\mathbf{x}) \{f(\mathbf{x}) - g(\psi^s(\mathbf{x}))\}^2 dX \\ = & \int_{D_X} p_s(\mathbf{x}) f^2(\mathbf{x}) dX \\ & + \int_{D_{X_{\text{obs}}}} -2g'(\mathbf{x}_{\text{obs}}) e_s(\mathbf{x}_{\text{obs}}) p_s(\mathbf{x}_{\text{obs}}) \\ & + g'^2(\mathbf{x}_{\text{obs}}) p_s(\mathbf{x}_{\text{obs}}) dX_{\text{obs}} \\ = & \int_{D_{X_{\text{obs}}}} p_s(\mathbf{x}_{\text{obs}}) \{g'(\mathbf{x}_{\text{obs}}) - e_s(\mathbf{x}_{\text{obs}})\}^2 \\ & - p_s(\mathbf{x}_{\text{obs}}) e_s^2(\mathbf{x}_{\text{obs}}) dX_{\text{obs}} \\ & + \int_{D_X} p_s(\mathbf{x}) f^2(\mathbf{x}) dX. \quad (11) \end{aligned}$$

となる。もし、欠測が起こるパターンが  $r = s$  の場合のみであれば、式 (11) を最小にする  $g'$  が学習すべきモデルであり、 $g'(\mathbf{x}_{\text{obs}}) = g(\mathbf{x}_{\text{obs}}, \psi'_{k+1}(\mathbf{x}_{\text{obs}}), \dots, \psi'_n(\mathbf{x}_{\text{obs}})) = e_s(\mathbf{x}_{\text{obs}})$  のときに最小となる。また、欠測がない場合では、式 (11) に式 (8) の第 1 項を加えたものを最小化する必要がある。

$f$  を  $g$  で近似可能であることを  $g \simeq f$  と表すことにする。このとき、 $g(\mathbf{x}_{\text{obs}}, \psi'_{k+1}(\mathbf{x}_{\text{obs}}), \dots, \psi'_n(\mathbf{x}_{\text{obs}})) = e_s(\mathbf{x}_{\text{obs}})$  を満たす  $\psi'_{k+1}, \dots, \psi'_n$  が、欠測が発生する場合における、誤差を最小にする置き換え値を定める関数となる。

以上の議論は、あくまでも  $g \simeq f$  を仮定したものであり、モデルが真の関数を再現できた場合におけるテスト時のリスクを最小にする理論的最適値であることに留意されたい。一方で、意図的代入法においても、確率的にデータを意図的に代入させるため、学習回数を重ねることでモデルが真の関数を学習することは理論上可能であり、上で得られた理想的な置き換え値の関数は意図的代入法においても重要な意味を持つと考えられる。

## 2.4 具体例

前節で検討した理論的考察を検証するため、具体的な例を使ってより詳細に議論をする。次元数を  $n = 2, R_1, R_2, \dots, R_n$  および  $X$  は独立 (したがって、 $p(\mathbf{x}, \mathbf{r}) = p(\mathbf{x}) \cdot p(r_1) p(r_2) \dots p(r_n)$ ) であるとする。また一般性を失うことなく、 $p(r_1 = 1) = \dots = p(r_{n-1} = 1) = 1.0, p(r_n = 0) = p_{\text{mis}}$  とし、欠測は第  $n$  次元目のみに確率  $p_{\text{mis}}$  で起こるものとする。

この条件における誤差の期待値は式 (8) より

$$\begin{aligned} \mathbb{E}[\delta(f, g)] = & (1 - p_{\text{mis}}) \int_{D_X} p(\mathbf{x}) \{f(\mathbf{x}) - g(\mathbf{x})\}^2 dX \\ & + p_{\text{mis}} \int_{D_X} p(\mathbf{x}) \{f(\mathbf{x}) - g(\psi^s(\mathbf{x}))\}^2 dX \quad (12) \end{aligned}$$

また、式 (11) より

$$\begin{aligned} \mathbb{E}[\delta(f, g)] &= (1 - p_{\text{mis}}) \int_{D_X} p(\mathbf{x}) \{f(\mathbf{x}) - g(\mathbf{x})\}^2 dX \\ &+ p_{\text{mis}} \int_{D_{X_{\text{obs}}}} \{p(\mathbf{x}_{\text{obs}}) \{g'(\mathbf{x}_{\text{obs}}) \\ &\quad - e(\mathbf{x}_{\text{obs}})^2 - p(\mathbf{x}_{\text{obs}}) e^2(\mathbf{x}_{\text{obs}})\} dX_{\text{obs}} \\ &+ p_{\text{mis}} \int_{D_X} p_s(\mathbf{x}) f^2(\mathbf{x}) dX \end{aligned} \quad (13)$$

である。ただし、式 (10) より、 $e(\mathbf{x}_{\text{obs}}) = \mathbb{E}_{X_n}[f(\mathbf{x})] = \int_{-\infty}^{\infty} p(x_n | \mathbf{x}_{\text{obs}}) f(\mathbf{x}) dX_n$  である。今、

$$\begin{aligned} \psi'_n(\mathbf{x}_{\text{obs}}) &= \\ \arg \min_{x_n} \{ &\int_{-\infty}^{\infty} p(x_n | \mathbf{x}_{\text{obs}}) f(\mathbf{x}_{\text{obs}}, x_n) dX_n \\ &- f(\mathbf{x}_{\text{obs}}, x_n) \}^2 \end{aligned} \quad (14)$$

となる  $\psi$  を代入値を定める関数とした場合に、 $g \simeq f$  であれば、誤差の期待値は最小となる。

### 3 数値実験

2.2 節では、本研究で取り扱うタスクに対してモデル学習時における意図的代入法を提案した。また、2.4 節では、より具体的な仮説を立てて、欠損が起こりうる場合の学習モデルを定式化し、誤差の期待値について理論的解析を行った。本章では、数値実験によりこれらの解析結果を実証し、提案法の有効性を議論する。実験では、意図的代入を行う確率を代入確率  $p_{\text{sub}}$ 、未知データのある要素が欠損する確率を欠損確率 (missing probability) とよび区別する。

実験の目的を以下のように設定する。

- 意図的代入の有効性調査。
- 欠損確率が予測精度に与える影響の調査。
- 意図的代入における代入値が予測性能に与える影響の調査。

#### 3.1 実験設定

実験では、入力ベクトルの次元数を  $n$ 、未知入力における欠損が確率  $p_{\text{mis}}$  で発生すると仮定する。また、一般性を失うことなく、欠損は最後の次元にのみ発生するものとする。学習モデルとして、ニューラルネットワークを用いる。機械学習のタスクを回帰とし、独立変数は多次元実数値ベクトル、従属変数を実数値とする。学習用データとして、定義域から一様乱数により入力を生成して独立変数とし、あらかじめ決められた関数の出力値を回帰モデル学習における教師信号 (従属変数) とする。ニューラルネットワークは、以下のハイパーパラメータを用いて学習される。

- 学習用データのサイズ  $N_{\text{training}}$  : 500
- 学習回数 : 1000
- ミニバッチのサイズ : 32

ニューラルネットワークの構成は以下のとおりである。

- 中間層の数 : 3

- 各中間層における隠れ層ユニットの数 : 50
- 活性化関数 : シグモイド関数
- 重み調整の最適化 : Adam 法

ニューラルネットワークの学習時に意図的代入を行う確率  $p_{\text{sub}}$  を 0.00, 0.25, 0.50, 0.75, 0.90, 1.00 と変化させ、代入値は定義域内で均等に 20 分割したときの端点 (合計 21) で変化させる。学習の目的関数を、教師信号とニューラルネットとの平均二乗誤差 (MSE) とし、これを最小化するように重みパラメータが調整される。

#### 3.2 ベンチマーク関数

以下のベンチマーク関数を用いて提案手法の有効性を調査する。また、それぞれのベンチマーク関数における、欠損値が存在する場合に予測誤差が最小となる代入値を示す。

$f_1$  (Sphere 関数) :

$$f_1(\mathbf{x}) = \sum_k^n x_k^2, \quad (-5 < x_k < 5) \quad (15)$$

いま  $n = 2$  とし、独立かつ一様に入力が生成されると仮定すると、 $p(x_1) = p(x_2) = \frac{1}{10}$  となる。また、 $p(x_1, x_2) = p(x_1)p(x_2)$  であることと式 (14) より、欠損値がある場合に予測誤差を最小化するような代入値は以下となる。

$$\begin{aligned} \psi'_2(x_1) &= \arg \min_{x_2} \left\{ \int_{-5}^5 \frac{1}{10} (x_1^2 + x_2^2) dx_2 - (x_1^2 + x_2^2) \right\}^2 \\ &= \pm \frac{x_1}{\sqrt{3}} \end{aligned} \quad (16)$$

$f_2$  (2 次元 2 次関数) :

$$f_2(\mathbf{x}) = (x_1 - x_2)^2, \quad (-5 < x_1, x_2 < 5) \quad (17)$$

Sphere 関数の時と同様に入力が独立かつ一様に生成されると仮定すると、式 (14) より欠損値がある場合に予測誤差を最小化するような代入値は以下となる。

$$\begin{aligned} \psi'_2(x_1) &= \arg \min_{x_2} \left\{ \int_{-5}^5 \frac{1}{10} (x_1 - x_2)^2 dx_2 - (x_1 - x_2)^2 \right\}^2 \\ &= x_1 \pm \sqrt{x_1^2 + \frac{25}{3}} \end{aligned} \quad (18)$$

#### 3.3 実験結果

Fig. 1 に、二つの関数 ( $f_1$  と  $f_2$ ) における各代入値と未知データの欠損確率の組合せに対する最適な代入確率  $p_{\text{sub}}$  を示す。Fig. 1 で、最も薄い水色の領域 (代入確率が 0) が意図的代入をしない場合に最も誤差が小さくなった代入値と欠損確率の組合せを表す。色が紫に近づくにつれて代入確率が大きくなり、それぞれの代入確率において誤差が最小となった代入値と欠損確率の組合せが各色の濃さにおける領域で表されている。図より、どちらの問題においても欠損確率が 10% ~ 40% の場合においては、よほど良い代入値を選択できない

限り意図的代入を用いたほうが良く、50%以上の欠損確率である場合においては意図的代入は効果があると言える。また、意図的代入を行う際の最適な代入確率については代入値と欠損確率に大きく依存しており、最適な代入確率を事前に知ることは不可能であるが、予想される欠損確率が高ければ高いほど代入確率も高く設定した方が良い結果が得られる傾向にあることがわかる。以上から、意図的代入法の有効性が示され、代入確率の設計指針を示すことができた。

続いて、Fig. 2に  $f_1$  におけるテスト用データに対する予測誤差、Fig. 3に  $f_2$  におけるテスト用データに対する予測誤差を示す。Fig. 2と Fig. 3は、各欠損確率と欠損値の組合せに対する10回試行から得られたテスト用データに対する平均予測誤差を示している。横軸は評価時における欠損確率、縦軸は学習時の意図的代入における代入値である。Fig. 2に示されているように、式(16)により求められた理論的に最適な代入値を使用した場合に、テストデータに対する予測誤差は小さくなる。また、理論値に近い値を使って代入した場合にも予測誤差は小さくなる。

$f_2$  では、 $\psi_2(x_1) = \alpha$  ( $\alpha$  は定数)であれば、式(12)が最小になるのは  $\alpha = 0$  のときである。したがって、 $p_{\text{sub}} = 1.0$  である場合を除いて、 $\psi_2(x_1) \approx 0$  のとき予測誤差は小さくなる。一方  $p_{\text{sub}} = 1.0$  の場合は、欠損する次元(実験では最後の要素  $n = 2$ )は常に学習中に無視される。したがって、その最後の次元はモデル学習におけるノイズのような働きを持つ。以上より、 $f_1$  と  $f_2$  は欠損値がある未知データの性能評価において正反対の性質を帯びることがわかる。

Fig. 4は関数  $f_2$  に対する数値実験結果である。3種類の代入値をそれぞれ用いた場合の未知データに対する予測誤差を比較している。図中、Theoryは式(18)から導出された理論的に最適な代入値を使った場合の予測誤差、Const. bestは21の端点を代入値としたときの最良の(最も小さい)予測誤差、Const. averageは21の端点を代入値としたときの予測誤差の平均値である。

Fig. 4に示されているように、理論的に最適な代入値を使うことで最も良い結果が得られている。また、 $p_{\text{sub}} = 1.0$  の時には、未知データにおける欠損確率が高くなればなるほど、学習済みのモデルの予測誤差は小さくなる。さらに、もっともよい予測性能は理論的に最適な代入値ではなく、Const. bestである場合に得られた。この結果に対する理由はまだ明確ではなく、今後調査していかなければならない。

最後に、以上の実験では、近似する対象の関数  $f$  がわかっている前提で理論値を計算し、実験をすることで議論を行った。しかし、そのような状況は実問題ではまずありえない。実際には、データからモデルを学習する際に真の関数  $f$  が分からず、最適な代入値  $\psi'_n(\mathbf{x}_{\text{obs}})$  を知ることができない。したがって、代入値を  $\psi'_n(\mathbf{x}_{\text{obs}})$  学習用データから適切に決定する方法が今後必要であり、研究課題である。

#### 4 おわりに

本研究では、機械学習における欠損値にロバストなモデル学習法を提案した。学習用データには欠損値が含まれていないが、未知データには欠損があることが

あらかじめ分かっていることが仮定されている。提案学習法では、学習用データのうち欠損可能性がある特徴量に意図的にあらかじめ決めた値を代入する。また、意図的な代入は確率的に行われる。

提案手法を理論的に解析することにより、未知データに欠損が発生する場合の予測誤差を推定した。その結果、ゼロや平均値などの単純な代入値を使用した場合、学習済みのモデルの未知データに対する予測性能が高くなる示された。また、未知データに対する欠損に対してロバストな学習時の代入値を理論的解析により求めることができた。

また、人工的な問題に対して、未知データに対する予測誤差の性能を調査した。数値実験の結果から、理論的に最適な値を代入値として用いることで未知データの欠損に対してロバストなモデルの妥当性を示すことができた。今後の課題として、実世界問題への適用がある。例えば、RoboCupのようなマルチエージェント環境における欠損値の取り扱いに対して、本研究の知見を生かすことが考えられる。

#### 参考文献

- 1) Amanda N. Baraldi and Craig K. Enders. An introduction to modern missing data analyses. *Journal of School Psychology*, 48(1):5–37, 2010.
- 2) Roderick J. A. Little and Donald B. Rubin. *Statistical Analysis with Missing Data*. John Wiley & Sons, Inc., New York, NY, USA, 1986.
- 3) Roderick J. A. Little and Donald B. Rubin. *Statistical analysis with missing data*. Wiley series in probability and mathematical statistics. Probability and mathematical statistics. Wiley, 2002.
- 4) Donald B. Rubin. Multiple imputation for non-response in surveys. *SERBIULA (sistema Librum 2.0)*, 137, 11 1989.
- 5) Donald B. Rubin. Multiple imputation after 18+ years. *Journal of the American Statistical Association*, 91(434):473–489, 1996.
- 6) Joseph L. Schafer and John W. Graham. Missing data: our view of the state of the art. *Psychological methods*, 7 2:147–77, 2002.
- 7) Volker Tresp, Subutai Ahmad, and Ralph Neuneier. Training neural networks with deficient data. In *Proceedings of the 6th International Conference on Neural Information Processing Systems*, NIPS'93, pages 128–135, San Francisco, CA, USA, 1993. Morgan Kaufmann Publishers Inc.
- 8) Alan C. Acock. Working with missing values. *Journal of Marriage and Family*, 67(4):1012–1028.




Fig. 1: best  $p_{\text{sub}}$  for each substitution value and test missing probability




Fig. 2: Test error maps on  $f_1$ (Sphere)






Fig. 3: Test error maps on  $f_2$




Fig. 4: Comparison of test error between theory and constant best and average

# 半導体アレイセンサとニューラルネットワークを用いた 臭い識別システムの構築

○岸田直也 磯川悌次郎 松井伸之 湯本高行 上浦尚武 (兵庫県立大学)

**概要** 本研究では半導体センサ群を用いた臭い識別システムを示す。本システムでは、センサ群から取り入れた時系列信号から得られる多次元ベクトルを入力とした階層型ニューラルネットワークにより4種類の臭い識別を行う。実験結果として、ノネナール、ジアセチル、アルコール、無臭という4つの臭い識別を行った結果を示す。

**キーワード:** ニューラルネットワーク, 臭い識別

## 1 はじめに

空気中の臭いを識別するシステムには、現在多くの応用分野が存在している。食品、飲料、化粧品といった分野では製品開発や品質評価などで専門家によるかぎ分け試験が行われている。しかし、この方法では検査者の体調や気分依存するため客観的な評価方法とはいえず、臭い識別システムの実用化が求められている。また、そのほかにも環境計測の分野における悪臭検査や環境状況の計測、医療分野における体臭チェックや医療診断、犯罪捜査の分野における麻薬探知などで臭い識別システムによる臭い検知の自動化、客観化が求められている<sup>1)</sup>。本研究では、体臭チェックに注目して、加齢臭などの体臭を検知する臭い識別システムの構築を目的とする。

臭いを測定する方法として、ガスクロマトグラフを使用する方法が挙げられる。ガスクロマトグラフを用いると、臭い成分を詳細に分析することが可能である<sup>2)</sup>。しかし、ガスクロマトグラフは装置が高価であり、また測定に時間を要するという問題がある。したがって、簡単に臭い識別を行うことができるシステムの構築が必要である。

臭いから信号を得ることができるセンサとしては、半導体ガスセンサや水晶振動子ガスセンサなどが開発され、すでに市販化されている<sup>3)4)</sup>。このようなガスセンサは、ガスクロマトグラフと比較して安価に測定装置を構築することが可能であり、また測定時間も短いという利点がある。しかしながら、体臭などの特定の臭いが提示された際にその臭いだけに選択的に反応するセンサを作成することは非常に困難である。様々な種類の臭いを識別する方法としては、汎用用途のセンサを複数用意し、検出対象の臭い物質を受容した時のこれらセンサ群の信号から識別するという方法が考えられる<sup>4)5)6)</sup>。

本研究では、このような考え方に基づいた複数のガスセンサから構成される臭い識別システムについて報告する。本システムでは、階層型ニューラルネットワークを用いて、センサ群から取り入れた時系列信号から得られる多次元ベクトルデータの識別を行った。また、体臭の臭い物質を中心としたノネナール、ジアセチル、アルコール、無臭という4つの臭いに対する認識実験を行った結果について報告する。

## 2 準備

### 2.1 臭い測定実験

本節では臭いの測定に使用する装置および測定方法について説明する。臭いの測定は、Fig. 1, 2で示すよ




Fig. 1: Experimental environment




Fig. 2: Sensor device

うなアクリル製容器(1辺20cmの立方体)内に配置された5台の半導体ガスセンサからなるガスセンサ群により行う。使用する半導体式ガスセンサはMQ-3, MQ-5, MQ-6, MQ-8, MQ-135 (HANWAEI製)である。測定物質として、ジアセチル(ミドル脂臭の原因物質)、ノネナール(加齢臭の原因物質)、アルコール除菌スプレー液(一般的なアルコール臭)を用いた。それぞれの測定物質をFig. 1で示すようなヘッドスペース内で気化した後にアクリル製容器内に注入してそれぞれの臭いを測定する。また、本研究では以上の3種類の臭い測定に加えて、アクリル製容器内に臭いを流していない無臭状態での測定を行った。この測定で得られたデータを無臭の臭いデータとする。

ヘッドスペース内で気化した臭いをアクリル製容器内に注入するためにコンプレッサで圧縮した空気をヘッドスペースに送り込む。このときの流量はデジタルフロースイッチで調節する。また、アクリル製容器内に注入された臭いを一様に分布させるために、アクリル製容器上部のファンで臭いを拡散させる。各ガスセンサからの出力電圧は一定間隔で量子化され、PCに送信される。サンプリング周期は0.01(s)とする。また、

測定物質の容量は全て 2.5( $\mu$ L) とする。

次に、測定手順について説明する。まず測定前の準備としてアクリル製容器内を無臭の状態にする。この無臭の状態とはアクリル製容器内に測定物質が残留しておらず、アクリル製容器の外と同じ空気の状態になっていることである。測定の手順については以下に示す。

1. マイクロピペットを用いて測定物質を脱脂綿に染み込ませる。
2. 脱脂綿をヘッドスペースに入れて密閉し、測定を開始する。
3. 直後にコンプレッサから空気を流し始め、デジタルフロースイッチで流量を 2.00(L/min) に調節する。
4. 100 秒間待機する。
5. 測定を終了する。

測定終了後はヘッドスペースから脱脂綿を取り出してアクリル製容器内を換気する。連続して測定を行う際は再びアクリル製容器内が無臭の状態であることを確認してから上記の手順で行う。

本研究では、以上のような測定を臭い物質（ノネナール、ジアセチル、アルコール）および無臭のそれぞれに対して 20 回実施する。この測定によって合計 80 データの多次元ベクトル測定データが得られる。これらの測定データは本研究の臭い識別システムにおける機械学習に利用される。

## 2.2 測定データの前処理

実際の臭いの測定データを機械学習の学習データとして扱うにあたって、測定データに対して前処理を行う必要がある。まず、測定で得られたセンサの出力電圧データについて、移動平均を取ることでより平滑化を行う。本研究では、平均を取る時間を 1(s) とする。ノネナールを 20 回測定し、平滑化を行った電圧変化の例を Fig. 3 に示す。Fig. 3 はノネナールの測定で得られた全ての電圧データを重ねてプロットした図である。このとき、各センサの出力電圧データは色分けしてプロットしており、同色のグラフは同じ種類のセンサの出力電圧データを表している。この図を見ると、いずれのセンサの出力電圧も単調増加していることがわかる。また、各センサの出力電圧は測定開始時点で 0(V) ではなく、初期バイアスが存在していることがわかる。この初期バイアスはセンサの種類ごとに異なっているだけでなく、同種類のセンサでも測定ごとに異なっていることがわかる。この初期バイアスの影響で臭いの識別が困難になることが考えられるため、全ての測定データから 0 秒時点の電圧値を減算し、電圧の変化量のみでのデータにする。これにより、初期バイアスを削除することができる。

4 種類の臭いについて、それぞれ電圧変化のデータから初期バイアス値を減算した結果を Fig. 4 に示す。Fig. 4 は各臭いの測定で得られた全ての電圧データに対して初期バイアスを減算した電圧変化量データを各臭いごとに重ねてプロットした図である。また、Fig. 3 と同様に各センサの電圧変化量は色分けしてプロットしている。Fig. 4(a) はノネナールの電圧変化量を表した図である。この図を見ると、いずれのセンサについても時間経過に伴い電圧値が増加していることがわかる。




Fig. 3: Voltage changes for nonenal

Fig. 4(b) はジアセチルの電圧変化量を表した図である。この図を見ると、いずれのセンサについても時間経過に伴い電圧値が増加しており、MQ-3, MQ-135 の電圧値は測定開始後 20(s) で急激に増加し、その後は飽和していることがわかる。Fig. 4(c) はアルコールの電圧変化量を表した図である。この図を見ると、いずれのセンサについても時間経過に伴い電圧値が増加しており、MQ-3, MQ-135 の電圧値は測定開始後 20(s) で急激に増加し、その後は飽和していることがわかる。ただし、ジアセチルの電圧変化量と比較するとアルコールの電圧変化量は小さい。Fig. 4(d) は無臭の電圧変化量を表した図である。この図を見ると、いずれのセンサについても電圧値がほとんど変化していないことがわかる。

最後に、本研究では学習データとして入力する際に、測定データに対して測定開始時点を開始点とした学習データとして使用する時間の秒数を減少させていき、それぞれで性能比較を行う。使用する秒数は 100(s) から 1(s) まで 1 秒ずつ減少させていき、合計 100 通りについて性能比較を行う。

## 2.3 識別手法

本研究では臭い識別システムを構築する識別器の識別手法として階層型ニューラルネットワーク（階層型 NN）を使用する。また、学習方式は誤差逆伝搬法による教師付き学習方式を使用する。

階層型 NN は入力層、出力層およびいくつかの中間層からなり、入力から出力の方向に層間の結合がある。各層は複数のニューロンユニットによって構成されている。このニューロンユニットの入出力関係は  $\{x_i\}$  をユニットへの入力、 $y$  を出力、 $w_i$  をそのユニットへの結合荷重とすると次式で表される。

$$y = f(\sum w_i x_i + b)$$

ここで、 $f$  は活性化関数、 $b$  はバイアスである。本研究では活性化関数として次式の ReLU 関数を使用する。

$$f(x) = \max(0, x)$$

本研究では学習に誤差逆伝搬法を使用する。誤差関数  $E$  は教師信号  $d$  と出力  $z$  の差を 2 乗して合計した次式で定義される。




Fig. 4: Voltage variations from sensors for four types of odors

$$E = \frac{1}{2} \sum_{i=1}^N |d_i - z_i|^2$$

このとき、 $N$  は教師信号  $d$  および出力  $z$  の個数とする。誤差逆伝搬法は誤差関数を各結合荷重で微分した値を用いて更新を行う。本研究では更新式として Adam を用いる<sup>7)</sup>。

### 3 実験結果

#### 3.1 識別器のパラメータ設定

本節では、実際の臭い物質を使用することにより 2.1 節にて紹介した臭い識別システムの性能評価を行う。本研究では入力層 1 層、中間層 2 層、出力層 1 層の階層型 NN を使用する。このネットワークにて使用するパラメータ群を Table.1 に示す。ただし、入力層のユニット数は入力データの次元数で決定される。また、入力データとして 2.2 節において説明した前処理を行った電圧の変化量データを使用する。入力次元数は学習データとして使用する時間で決定される。例えば使用する時間を 100(s) とした場合、5 つのセンサから得られるデータについて  $5 \times 100 = 500$  次元のデータとなる。

#### 3.2 識別結果

臭い物質（ノネナール、ジアセチル、アルコール）および無臭について、学習データとして使用する秒数を変化させて識別実験を行った。使用する秒数の違いによる識別率の変化 Fig. 5 に示す。この図において、横軸は使用した秒数、縦軸は識別率である。本研究では 5 分割交差検定法を用いて識別率を算出した。

Table 1: Parameters for neural network

Number of units in hidden layer 1	500
Number of units in hidden layer 2	100
Number of units in output layer	4
Maximum number of iterations	30000
Tolerance for the optimization	0.001




Fig. 5: Classification rates with respect to duration used as learning data

Fig. 5 より、使用する秒数が 20(s) 以上の場合、識別率はほぼ 100% であるが、使用する秒数が 20(s) より小さい場合、識別率が下がることがわかる。

学習データとして使用する秒数による各識別結果の混同行列を Table.2 に示す。Table.2(a) は使用する秒数が 10(s) の場合の混同行列で、Table.2(b) は使用する

Table 2: Confusion matrix of classification result with respect to each duration for learning data, where N, D, A, and O denote Nonenal, Diacetyl, Alcohol, and Odorless, respectively

(a) Duration for learning data : 10(s)

		Predicted odor			
		N	D	A	O
Actual odor	N	8	0	0	12
	D	0	19	1	0
	A	0	0	20	0
	O	8	0	0	12

(b) Duration for learning data : 20(s)

		Predicted odor			
		N	D	A	O
Actual odor	N	20	0	0	0
	D	0	20	0	0
	A	0	0	20	0
	O	0	0	0	20

秒数が 20(s) の場合の混同行列である。Table.2(a) より使用する秒数が 10(s) の場合、ノネナルを無臭と間違えていることがわかる。また、無臭をノネナルと間違えていることも多いことがわかる。このことから、使用する秒数が 10(s) の場合、本システムではノネナルと無臭の判別が困難であることがわかる。原因としては、ノネナルと無臭は他の臭いと比較して電圧変化量が小さいため、測定時間 10(s) まではほとんど同じ傾向を持つデータとなってしまうからだと考えられる。Table.2(b) より使用する秒数が 20(s) の場合、いずれの臭いについても判別できていることがわかる。

#### 4 結論

本論文では、ノネナルなどの特定の臭い物質の臭いを識別するための臭い識別システムを構築し、その性能評価を行った。提案システムは、5 台の半導体ガスセンサから構成されるセンサ部とそれらの出力信号から得られる多次元ベクトルデータから臭いの識別を行う識別部によって構成されている。多次元ベクトルデータを識別するために階層型 NN を使用した。性能評価実験として、臭い物質（ノネナル、ジアセチル、アルコール）および無臭をセンサ入力として用いた識別実験をおこなった。このときの入力データについて、学習データとして使用する時間の秒数を変化させて識別率を算出した。その結果として、本システムでは使用する時間の秒数が 20(s) 以上である場合にほぼ 100% の識別率が得られており、実験で使用した 4 種類の臭いの識別が可能であることが示された。

今後の展望として、少数データでの臭い識別システムの構築が挙げられる。様々な種類の臭いの識別や詳細な臭い識別を行うためには多数の測定データが必要になる。しかし、臭いの測定には換気などの手間がかかるため、多数の測定データを得ることが難しいという問題がある。この問題を解消する方法として、敵対的生成ネットワーク<sup>8)</sup>による臭いデータの生成が挙げられる。これを利用して、少数の臭いデータから多数の新しい臭いデータを生成し、その生成データを用いて

臭い識別システムの学習を行うことにより、少数データでの臭い識別が可能ではないかと考える。

#### 参考文献

- 1) 中本高道, 森泉豊栄:ニューラルネットワークを用いたにおいセンサー, 応用物理, 58 7 号, 1045/1054 (1989)
- 2) 津田孝雄:クロマトグラフィー分離の仕組みと応用 (第 2 版), 丸善出版 (1995)
- 3) D. James, S.M. Scott, Z. Ali,W.T. O'Hare: Chemical sensors for electronic nose systems. *Microchim, Acta* 149, 1/17 (2005)
- 4) Simeng Chen, Yuchao Wang, Seokheun Choi: Applications and Technology of Electronic Nose for Clinical Diagnosis, *Scientific Research, Open Journal of Applied Biosensor-2*, 39/50 (2013)
- 5) Jun Fu, Guang Li, Yuqi Qin, Walter J.Freeman: A pattern recognition method for electronic noses based on an olfactory neural network, *Sensors and Actuators, B* 125, 489/497 (2009)
- 6) Aiphus D. Wilson, Manuela Baiuto: Applications and Advances in Electronic-Nose Technologies, *Sensors*, 9, 5099/5148 (2009)
- 7) D.KingmaandJ.Ba:Adam: A method for stochastic optimization, arXiv preprint arXiv:1412.6980 (2014)
- 8) Goodfellow, Ian and Pouget-Abadie, Jean and Mirza, Mehdi and Xu, Bing and Warde-Farley, David and Ozair, Sherjil and Courville, Aaron and Bengio, Yoshua:Generative adversarial nets, *Advances in neural information processing systems*, 2672/2680 (2014)



# 乳房X線画像における画像診断が難しい腫瘍に対する 深層学習を用いた良悪性鑑別の試み

○野呂恭平 (東北大学) 張曉勇 (仙台高等専門学校) 市地慶  
高根侑美 柳垣聡 高野寛己 石橋忠司 本間経康 (東北大学)

## Performance evaluation of deep learning for tumor with difficulty to diagnose between benign and malignant in mammography

\* Noro Kyohei (Tohoku University), Xiaoyong Zhang (Sendai National College of Technology),  
Kei Ichiji, Yumi Takane, Satoru Yanagaki, Hiroki Takano, Tadashi Ishibashi, Noriyasu Homma  
(Tohoku University)

**Abstract**—The purpose of this paper is to investigate the performance of deep learning against a special type of mammographic masses to which even an expert doctor strongly needs a computer-aided diagnosis for accurate diagnosis of breast cancer. In fact, it is still not clear that how deep learning is effective for such difficult cases. To go beyond image diagnosis, we used biopsy results, instead of mammographic diagnosis, to train a deep neural network. Experiments were conducted on Digital Database for Screening Mammography database, in which 1,066 benign and 954 malignant mammograms with biopsy results were used in our experiment. Experimental results showed that it achieved 66.4% accuracy; it is remarkably more accurate than radiologists.

**Key Words:** Deep convolutional neural network (DCNN), Computer-aided diagnosis (CAD), Mammogram, BI-RADS category

### 1 はじめに

乳癌は日本人女性の癌の中でも罹患率1位、死亡率2位であり、両者ともに近年上昇傾向にある<sup>1)</sup>。一方で、乳癌は早期の治療によって良好な予後が期待できるため、早期発見が重要であり、乳房X線撮影(マンモグラフィ)は有効な手法として知られている。乳がん検診の早期発見の啓発運動の広がりによって、乳がん検診の受診者は年々増加傾向にあるが、それに伴って画像診断医の負担増加が懸念されている。そこで、コンピュータによる画像解析技術を用いて医師の補助を行うコンピュータ支援診断(Computer-aided diagnosis: CAD)システムの開発が進められている<sup>2)</sup>。

CADシステムには様々なアプローチがあるが、近年注目を集めているのが深層学習という手法である。深層学習は対象を認識するための効果的な特徴量設計を学習により自動化することが可能で、手作業では不可能であった複雑な特徴を抽出することができる。自然画像の分野においては従来法を上回る性能を発揮しており<sup>3)</sup>、CADの分野においても期待されている。

先行研究<sup>4)</sup>において、深層学習の基本的なアーキテクチャである AlexNet<sup>3)</sup>を用いて乳がんの典型的な画像所見の1つである腫瘍の良悪性を70%的中させるという報告がされている。また、別の先行研究<sup>5)</sup>においては AlexNet と同等の特異度を維持しつつ90%の悪性的中率を達成している。しかし、これらの先行研究においては、比較的診断しやすい画像データを用いるなど、どのような腫瘍の識別に成功、また失敗したのかという詳しい検証がなされていない。したがって医師が診断の補助を求めるような、診断が難しい腫瘍に対して、どの程度正確な鑑別が行えるのかわかっていないという問題がある。

Table 1: BI-RADs category

Category	
0	incomplete, not enough information
1	Negative
2	benign findings
3	probably benign (Probability of malignancy: ~2%)
4	suspicious abnormality (Probability of malignancy: 2~95%)
5	highly suspicious of malignancy (Probability of malignancy: 95%~)




Fig. 1: Number of masses by category




Fig. 2: The AlexNet in which the last fully-connected layer (fc 8) is replaced with two neurons corresponding to the benign and malignant

診断の難しさの指標としては、Breast Imaging Reporting and Data System: BI-RADS<sup>6)</sup>のカテゴリ分類がある。画像診断において腫瘍を発見した場合、医師はその腫瘍の悪性の確信度を6段階の指標で判別する (Table 1)。カテゴリは大きいほど悪性の可能性が高いことを意味する。Fig.1に、本研究で使用したデータセットにおけるカテゴリ別の良悪性の腫瘍枚数を示す。注目したいのは、カテゴリ4に分類された腫瘍は悪性疑いで精密検査の対象となるが、実際に悪性であったものは全体の48%に留まっていることである。カテゴリ4は悪性の可能性が2~95%と非常に範囲が広く、細胞生検を行わなければ結果がわからない集団である。したがってカテゴリ4の腫瘍は医師であっても画像診断が難しい腫瘍であるといえ、このことはマンモグラフィ検診における過剰生検として問題になっている<sup>7)</sup>。そこで本研究では、BI-RADSカテゴリ4のような診断の難しい画像を対象に、深層学習の鑑別性能を詳しく検証し、臨床における利用価値の高いCADシステム実現の可能性について考察する。

## 2 実験手法

### 2.1 DCNNの基本構造

本研究で識別器として用いる深層畳み込みニューラルネットワーク (deep convolutional neural network: DCNN) は、KrizhevskyらによるAlexNetとほぼ同様の構造を持つものである。Fig.2に示すように、このDCNNは5層のconvolution層と3層のfully-connected層を持つ。このDCNNは227\*227の画像を入力として受け取る。オリジナルのAlexNetは1,000クラスのクラス確率を出力するが、本研究では2クラスに変更している。convolution層(Conv 1~6)は特徴抽出を行う層であり、pooling層(Pool 1,2)は次元を削減することにより位置変動に対するロバスト性を強固にする層である。Normalization層(Norm 1,2)は入力を正規化する働きを持つ。Fully connected層(fc 6~8)は抽出された特徴を用いて識別を行う層である。詳細は参考文献を参照されたい。なお、本研究における学習はすべて誤差逆伝播法を用いて行った。

### 2.2 DCNNの転移学習

DCNNの学習には大量の画像が必要となるが、乳房

X線画像で大規模なデータを集めることは難しい。そこで、自然画像で一度学習させたネットワークを別のタスクに応用する、転移学習という手法を用いた。腫瘍識別の前に、約120万枚の自然画像からなるImageNet<sup>8)</sup>データセットを用いてDCNNの事前学習を行う。DCNNのうち、浅い層ではエッジや色といった単純で普遍的な特徴が抽出されることが知られており、これらの画像特徴はほかの様々な対象の識別にも有効であることが明らかになっている。ImageNetデータセットの1000クラス、120万枚を用いて学習させたDCNNを用い、最終層のみを2クラスのニューラルネットワークに置き換えた。この手法はfine-tuningと呼ばれる。この手法により、自然画像で学習した特徴抽出能力を転用することができ、より少数の画像でも学習が可能となると期待される。

## 3 実験結果

### 3.1 実験データセット

実験に用いる医用画像は、乳房X線画像の公開データベースであるDigital Database for Screening Mammography: DDSM<sup>9)</sup>の臨床画像をもとに作成した。




Fig. 3: Example of mammogram

DDSM は、27 歳から 91 歳までの 3500 人の乳房画像が、画像診断結果だけでなく病理診断による精密検査結果とともに登録されている。原画像のサイズは  $5000 \times 3000$  pixels 程度、解像度は  $42 \mu\text{m}/\text{pixel}$  もしくは  $50 \mu\text{m}/\text{pixel}$  である。本実験では、臨床画像から、医師が作成した腫瘍の正解位置データをもとに正方形の ROI を切り出し、 $227 \text{ pixel}$  四方にリサイズして使用している。また、良悪性鑑別の正解は精密検査結果を用いた。Fig. 3 (a) - (c) は、臨床画像および正解位置データとそこから切り出した ROI の例である。切り出した ROI のカテゴリ、良悪性別の枚数は Table 2 のようになった。この画像を用いて、6 分割 cross-validation を用いて評価を行った。学習には全カテゴリの画像を用い、テスト画像はカテゴリ 4 の画像から選択し、良悪性それぞれ 72 枚ずつ、計 144 枚を選択した。

Table 2: Experimental data (Number of ROIs)


Category	0	1	2	3	4	5
Benign	139	0	94	346	476	11
Malignant	31	3	1	87	430	402

### 3.2 識別性能の評価


良悪性識別性能の評価として、閾値 0.5 とした時の感度(sensitivity)を用いた。6 分割 cross-validation の結果を Table 3 に示す。平均として、感度 66.4%、特異度 64.6% という結果が得られた。これを DDSM データベースにおける医師の感度 48% と比較すると、医師の診断結果より感度がよいという結果になった。

Table 3: Result of 6-fold cross validation

CV	Sensitivity
1	54.9%
2	73.2%
3	74.6%
4	67.6%
5	66.2%
6	62.0%
Average	66.4%
Medical Doctors	48.0%



(a) Images classified as benign



(b) Images classified as malignant

Fig. 4: Images and score  
(Score is a probability of malignancy)

## 4 考察

腫瘍の中で DCNN が良性、悪性の可能性が特に高いと判定した画像のそれぞれの例を示す (Fig. 4). 画像を比較すると、良性、悪性に分類された画像間で画像特徴に差が見られた。すなわち、良性と分類された画像は全体の傾向として円形に近く、境界が明瞭であった。これに対して、悪性の腫瘍では形状が円形ではない複雑な形をしており、かつスピキュラと呼ばれる針状の突起が見られる物もあった。また腫瘍の辺縁は不明瞭で、正常組織との境界が不明確であった。これら 2 集団の間に見えた画像特徴の差異は、医師が腫瘍の良悪性鑑別の際に用いる画像解剖学的な良悪性の特徴と一致している。したがって、今回用いた DCNN は診断の基本となる画像解剖学的判別能力を獲得できた可能性が高く、その判別基準を医師が理解しやすく臨床で利用しやすい CAD システムにつながる事が期待できる。

また、Table 3 に示すように、診断が難しいカテゴリ 4 の腫瘍の良悪性を、医師の画像診断結果よりも高い感度で判別することができた。この結果は、画像診断が難しい症例であっても、精密検査結果で訓練した深層学習を用いることで、より正確な良悪性鑑別が可能であることを示唆するものである。

一方、今回は DCNN として比較的単純な AlexNet を用いたため、その性能は限定的である。今後は、自然画像においてより高性能が示されている DCNN を用いることで、さらなる性能向上が期待できる。

## 5 まとめ

DCNN は、乳房 X 線画像の CAD システム開発の分野でも高性能を発揮し、非常に注目を集めている。本研究では、これまで未検討であった、医師が診断支援を必要とするような診断の難しいカテゴリ 4 の腫瘍を例に、DCNN の性能を検証した。その結果、医師の画像診断結果よりも正確な良悪性鑑別が可能であることが示唆された。この意味において、深層学習は医師の診断能力を超えることが可能であり、臨床きわめて有用な CAD システムの実現が期待される。さらに、深層学習で得られた特徴を画像解剖学的に医師が詳細に検討することで、これまで知られていなかった、良悪性鑑別に有用な新しい特徴量 (所見) が発見される可能性もある。これは、放射線診断学の新たな可能性を切り拓くものであり、今後の展開が期待される。

## 謝辞

本研究の一部は、JSPS 科研費 18K19892 ならびに東北大学スマート・エイジング学際重点研究センターの助成を受けた。

## 参考文献

- 1) Katanoda K, Sobue T, Tanaka H, Miyashiro I (eds.): JACR Monograph Supplement No. 2.(2016)
- 2) J. Tang, R. M. Rangayyan, J. Xu, I. E. Naqa, and Y. Yang: Computer-Aided Detection and Diagnosis of Breast Cancer With Mammography: Recent Advances, *IEEE Transactions on Information Technology in Biomedicine*, 13-2, 236/251, (2009).
- 3) A. Krizhevski, I. Sutskever, and G. E. Hinton: ImageNet Classification with Deep Convolutional Neural Networks, In Proc. NIPS, (2012).
- 4) Zhang, Xiaoyong, et al. "Classification of mammographic masses by deep learning." *Society of Instrument and Control Engineers of Japan (SICE), 2017 56th Annual Conference of the IEEE*, 793/796, (2017).
- 5) Ribli, Dezsó, et al. Detecting and classifying lesions in mammograms with Deep Learning. *Scientific reports*, 8.1: 4165, (2018).
- 6) American College of Radiology. BI-RADS Committee: Breast imaging reporting and data system. *American College of Radiology*, (1998).
- 7) Bolejko, A., Zackrisson, S., Hagell, P., & Wann - Hansson, C: A roller coaster of emotions and sense- coping with the perceived psychosocial consequences of a false - positive screening mammography, *Journal of clinical nursing*, 23(13-14), 2053/2062, (2014).
- 8) J. Deng, W. Dong, R. Socher, L. J. Li, K. Li, and L. Fei-Fei: ImageNet: A Large-Scale Hierarchical Image Database, *CVPR09*, 248/255, (2009).
- 9) M. Heath, K. Bowyer, D. Kopans, R. Moore and W. P. Kegelmeyer: The Digital Database for Screening Mammography, *Proceedings of the Fifth International Workshop on Digital Mammography*, 212/218, (2001).

# 等価ペナルティ係数法を導入した差分進化による制約付き最適化

○高濱徹行 (広島市立大学) 阪井節子 (広島修道大学)

## An Equivalent Penalty Coefficient Method for Constrained Optimization by Differential Evolution

\*T. Takahama (Hiroshima City University) and S. Sakai (Hiroshima Shudo University)

**Abstract**— The penalty function method has been widely used for solving constrained optimization problems. In the method, an extended objective function, which is the sum of the objective value and the constraint violation weighted by the penalty coefficient, is optimized. However, it is difficult to control the coefficient properly because proper control varies in each problem. In this study, an equivalent penalty coefficient (EPC) method is proposed. In the EPC method, a new solution is compared with the old solution and the EPC value, which makes the two extended objective values of the solutions the same, is obtained for the new solution. If a small EPC value is selected as the penalty coefficient value, a search that gives priority to optimizing objective values will be performed. If a large EPC value is selected as the penalty coefficient, a search that gives priority to optimizing constraint violations will be performed. Furthermore, a method to select an appropriate EPC value by using the ratio of feasible individuals, which realizes adaptive control of the penalty coefficient, is proposed. The proposed method is introduced to differential evolution. The nature of the proposed method is shown by solving several constrained optimization problems.

**Key Words:** penalty function method, penalty coefficient, constrained optimization, differential evolution

### 1 はじめに

制約付き最適化問題は与えられた制約の下で目的関数を最適化する問題である。この中でも特に制約付き非線形最適化問題は実世界に頻繁に出現する重要な最適化問題である。制約付き非線形最適化問題の解法としては、逐次2次計画法、射影法、一般縮小勾配法などの効率的な方法が存在する。しかし、これらの方法は目的関数の微分可能性や制約領域の凸性など問題に対して幾つかの条件を仮定している。したがって、これらの方法を様々な分野における問題に広く適用することは困難である。

これに対して、目的関数の値だけを利用して制約のない非線形最適化問題を解決する方法が提案されている。この方法は直接探索法 (direct search method) と呼ばれ、様々な問題に適用することができるが、制約付き非線形最適化問題を直接解くことはできない。本研究では、直接探索法を制約付き非線形最適化問題に適用する方法について考察する。

制約付き最適化問題を直接探索法によって解く際には、目的関数だけではなく、一般に複数の制約も最適化する必要がある。制約付き最適化のためには、目的関数の最適化と制約の最適化という2種類の最適化が含まれるため、2つの最適化のバランスを適切に取る必要がある。制約を扱う方法は、同時に最適化する目的の数に基づき、以下のように分類できる。

#### (1) 目的関数のみを最適化する方法

制約を満足する一つ以上の探索点を初期点として準備し、制約を満足する探索点のみを考慮してゆくことにより、制約の最適化を省略する方法であり、death penalty法とも呼ばれる。探索の過程で得られた点が制約を満足しない場合には、単純に無視されるか、制約を満足するように修正される。例えば、遺伝的アルゴリズム (Genetic Algorithm, GA) において、制約を満足した探索点を参照して制約を満足しない探索点を修正する方法が提案されている [1-3]。また、パーティクルスワーム最適化 (Particle Swarm Optimization, PSO) [4-6]

において、制約を満足しない探索点を無視し、既知の制約を満足する探索点に置換する方法も提案されている [7]。これらの方法は制約領域が比較的広い場合には有効である。しかし、実際には制約の厳しい問題も多く、特に等式制約を含む問題では、初期点を準備したり探索点を修正することは不可能に近い。

#### (2) 目的関数と制約逸脱度 (constraint violation) の荷重和を最適化する方法

複数の制約条件を組み合わせて制約逸脱度を定義し、目的関数と制約逸脱度の荷重和を求め、その荷重和の一目的最適化問題として解く方法である。制約逸脱度は目的関数に対するペナルティと考えられるため、この方法は一般にペナルティ関数法 (penalty function method) と呼ばれ、目的関数と制約逸脱度の荷重和は拡張目的関数 (extended objective function) と呼ばれている。ペナルティ関数法では、制約逸脱度の強さを調整するための荷重であるペナルティ係数 (penalty coefficient) を適切に選択することが困難であるという問題点がある。ペナルティ係数が大きいと、制約を満足する解は得られるが、目的関数の最適化が不十分になり、質の高い解を得ることが困難になる。逆にペナルティ係数が小さいと、目的関数は最適化されるが、制約の最適化が不十分になり、実行可能解を得ることが困難になる。ペナルティ係数を動的に調整する方法もあるが、適切な調整方法は問題に依存するため、一般的な調整方法を実現するのは困難であるという問題がある。

#### (3) 目的関数と制約逸脱度を辞書式比較により最適化する方法

目的関数と制約逸脱度を分離して扱い、制約逸脱度を優先する辞書式比較により一目的化して解く方法である。例えば、GAにおいて辞書式比較を実現する拡張目的関数を利用する方法が提案されている [8]。これは、制約を満足しない探索点の拡張目的関数値を、集団中の制約を満足する探索点における最悪の目的関数値と制約逸脱度との和として与える方法である。進化的戦



略 (Evolutionary Strategy) において、単に制約逸脱度を優先するのではなく、ある確率で制約逸脱度を無視し目的関数のみで比較を行うという拡張された辞書式比較により最適化を行う方法が提案されている [9]。これにより、制約条件が確率的に緩和され、質の高い実行可能解が得られることが示されている。より一般的な方法として、直接探索法全般に対して、制約条件を緩和することができる辞書式比較である  $\alpha$  レベル比較を使用する  $\alpha$  制約法 [10–14] および  $\epsilon$  比較を使用する  $\epsilon$  制約法 [15–18] が提案されている。 $\alpha$  制約法および  $\epsilon$  制約法は、直接探索法における比較演算子を  $\alpha$  レベル比較および  $\epsilon$  レベル比較に置換することにより、制約のない問題に対する最適化アルゴリズムを制約付きの最適化アルゴリズムに変換する方法、すなわちアルゴリズム変換法である。 $\alpha$  および  $\epsilon$  制約法は、制約条件を緩和することにより、等式制約を含むような制約条件の厳しい問題に対しても適用することができる。

#### (4) 目的関数と各制約の多目的問題として解く方法

目的関数と一般に複数の制約関数を多目的最適化問題として解く方法である [19, 20]。制約が複雑な問題に有効であると期待されるが、多目的最適化問題は一目的問題と比較すると非常に困難な問題であり、一般に多くの計算量を必要とするという問題点がある。

本研究では、進化的アルゴリズムなどの集団に基づく最適化において、集団から適切なペナルティ係数を設定するための情報として、等価ペナルティ係数 (Equivalent Penalty Coefficient, EPC) 値を用いることを提案する。EPC 値を用いてペナルティ係数を動的に調整する方法である等価ペナルティ法を提案し、工業設計問題に適用することによりその有効性を示す。

## 2 制約付き最適化問題

### 2.1 定義

本論文では、次のような不等式制約、等式制約、上下制限制約を持つ最適化問題 (P) を考える。目的関数および制約条件がともに線形の場合が線形計画問題、その他の場合が非線形計画問題である。

$$(P) \begin{aligned} & \text{minimize} && f(\mathbf{x}) \\ & \text{subject to} && g_j(\mathbf{x}) \leq 0, \quad j = 1, \dots, q \\ & && h_j(\mathbf{x}) = 0, \quad j = q + 1, \dots, m \\ & && l_i \leq x_i \leq u_i, \quad i = 1, \dots, n \end{aligned} \quad (1)$$

ここで、 $\mathbf{x} = (x_1, \dots, x_n)$  は  $n$  次元決定変数ベクトル、 $f(\mathbf{x})$  は目的関数、 $g_j(\mathbf{x}) \leq 0$  は  $q$  個の不等式制約、 $h_j(\mathbf{x}) = 0$  は  $m - q$  個の等式制約であり、 $f, g, h$  は線形あるいは非線形の実数値関数である。 $l_i, u_i$  はそれぞれ、 $n$  個の決定変数  $x_i$  の下限値、上限値である。さらに、以下では全ての制約を満足する領域を実行可能領域 (feasible region)、上下制限制約を満足する領域を探索領域 (search space) と呼ぶことにする。

### 2.2 ペナルティ関数法

制約付き最適化では、目的関数の最適化と制約の最適化という2つの最適化を同時に行う必要がある。ペナルティ関数法では、目的関数  $f(\mathbf{x})$  に制約逸脱度  $\phi(\mathbf{x})$  をペナルティとして加えることにより、制約付き最適化問題を以下のような制約無し最適化問題に変換する。

$$F(\mathbf{x}) = f(\mathbf{x}) + \rho\phi(\mathbf{x}) \quad (2)$$

ここで、 $F$  は拡張目的関数、 $\rho$  はペナルティ係数 ( $\rho > 0$ ) である。ペナルティ係数を  $\infty$  に向けて増加させることにより制約逸脱度が 0 に収束し、実行可能解を得ることができる。

制約逸脱度  $\phi(\mathbf{x})$  の定義としては、以下の例がある。

$$\phi(\mathbf{x}) = \max\{\max_j\{0, g_j(\mathbf{x})\}, \max_j|h_j(\mathbf{x})|\} \quad (3)$$

$$\phi(\mathbf{x}) = \sum_j \|\max\{0, g_j(\mathbf{x})\}\|^p + \sum_j \|h_j(\mathbf{x})\|^q \quad (4)$$

ここで  $p$  は正の数である。

## 3 集団的降下法における等価ペナルティ係数値

### 3.1 集団的降下法

DE や PSO などのように解集団による最適化の際に降下法を利用した最適化法である集団的降下法 (population-based descent method) について説明する。集団的降下法は一般に以下のように記述できる。

1. 初期化: 解をランダムに生成し集団  $P = \{\mathbf{x}_i, i = 1, 2, \dots, N\}$  ( $N$  は解の数) を構成する
2. 評価: 全ての解を評価する
3. 終了判定: 終了条件を満足すれば終了する
4. 各解に対して、
  - (a) 生成: 各解  $\mathbf{x}_i$  と集団  $P$  の情報に基づき新しい解  $\mathbf{x}'_i$  を生成する
  - (b) 評価: 新しい解を評価する
  - (c) 更新: 新しい解が古い解より良ければ、古い解を新しい解で置換する
5. 3. へ戻る

### 3.2 等価ペナルティ係数法

集団的降下法では、古い解  $\mathbf{x}_i$  と新しい解  $\mathbf{x}'_i$  を比較し、新しい解が古い解より良ければ古い解を新しい解で置換する。2つの解を比較したとき、 $\mathbf{x}'_i$  の関数値と制約逸脱度の両者が  $\mathbf{x}_i$  より優れている場合は、ペナルティ係数の値に無関係に  $\mathbf{x}'_i$  は拡張目的関数値が良い解となる、すなわち、任意の  $\rho$  について  $F(\mathbf{x}') < F(\mathbf{x})$  が成立する。 $\mathbf{x}$  と  $\mathbf{x}'$  の関係が逆の場合も同様である。また、関数値と制約逸脱度が同じ場合は、任意の  $\rho$  について  $F(\mathbf{x}) = F(\mathbf{x}')$  が成立する。したがって、以下の条件が成り立つ場合にはペナルティ係数を決定する必要が無い。

$$\begin{aligned} & f(\mathbf{x}') \leq f(\mathbf{x}) \text{ and } \phi(\mathbf{x}') \leq \phi(\mathbf{x}) \\ \text{or } & f(\mathbf{x}) \leq f(\mathbf{x}') \text{ and } \phi(\mathbf{x}) \leq \phi(\mathbf{x}') \end{aligned} \quad (5)$$

これ以外の場合、関数値が優れているが制約逸脱度が劣っている解と関数値が劣っているが制約逸脱度が優れている解が存在する。前者が  $\mathbf{x}_i$  後者が  $\mathbf{x}'_i$  と仮定すると、 $f(\mathbf{x}_i) < f(\mathbf{x}'_i)$ 、 $\phi(\mathbf{x}_i) > \phi(\mathbf{x}'_i)$  である。この2つの解の拡張関数値が一致するペナルティ係数値を等

価ペナルティ係数値 (EPC 値) と呼ぶことにする。EPC 値を  $\rho_i$  で表現すると以下の関係が成立する。

$$f(\mathbf{x}_i) + \rho_i \phi(\mathbf{x}_i) = f(\mathbf{x}'_i) + \rho_i \phi(\mathbf{x}'_i) \quad (6)$$

$$\rho_i = \frac{f(\mathbf{x}'_i) - f(\mathbf{x}_i)}{\phi(\mathbf{x}_i) - \phi(\mathbf{x}'_i)} \quad (7)$$

このとき、ペナルティ係数が EPC 値より大きければ  $F(\mathbf{x}_i) > F(\mathbf{x}'_i)$  となるため、制約逸脱度が優れている  $\mathbf{x}'_i$  が良い解となる。逆にペナルティ係数が EPC 値より小さければ  $F(\mathbf{x}_i) < F(\mathbf{x}'_i)$  となるため、目的関数値が優れている  $\mathbf{x}_i$  が良い解となる。

$\rho_i$  を昇順にソートしたリストを  $H = \{\rho_k | \rho_k < \rho_{k+1}, k = 1, 2, \dots\}$  とする。適応的にペナルティ係数を制御するために、アルゴリズムパラメータとして制約優先率 (constraint priority rate)  $R_{cp}$  を導入する。このとき、 $H$  の  $R_{cp}|H|$  番目の要素の値をペナルティ係数  $\rho$  に設定するために、以下のように線形補間を利用する。

$$\rho = \begin{cases} R_{cp}|H|\rho_1 & (\lfloor R_{cp}|H| \rfloor < 1) \\ \rho_{\lfloor R_{cp}|H| \rfloor} & (R_{cp} > 1) \\ \rho_{\lfloor R_{cp}|H| \rfloor} + \Delta R_{cp} \Delta \rho & (\text{otherwise}) \end{cases} \quad (8)$$

$$\Delta R_{cp} = R_{cp}|H| - \lfloor R_{cp}|H| \rfloor \quad (9)$$

$$\Delta \rho = \rho_{\lfloor R_{cp}|H| \rfloor} - \rho_{\lfloor R_{cp}|H| \rfloor} \quad (10)$$

ただし、 $|H|$  は  $H$  の要素数、 $\lfloor \cdot \rfloor$  は整数値への切り捨て、 $\lceil \cdot \rceil$  は整数値への切り上げである。 $R_{cp} = 0$  のときは  $\rho = 0$  となり、目的関数値のみの最適化を行うことになる。 $R_{cp} > 1$  のときは  $\rho > \rho_{|H|}$  となり、2つの解の比較で制約逸脱度が優先されることになるため、制約逸脱度のみの最適化を行うことになる。このように等価ペナルティ係数法は、集団的降下法のように、古い解と新しい解を一对比較する集団的最適化手法に用いることができる。

さらに、ペナルティ係数値の急激な変化を避けるために、以下のように指数移動平均を用いて世代  $t$  のペナルティ係数値  $\rho(t)$  を決定する。

$$\rho(t) = \begin{cases} 0.5\rho(t-1) + 0.5\rho_t & (t > 1) \\ \rho_t & (t = 1) \end{cases} \quad (11)$$

ここで、 $\rho_t$  は、式 (8) で求めた世代  $t$  の  $\rho$  値である。制約優先度が 1 を超えた場合、ペナルティ係数を  $\infty$  に設定するのと同じ効果がある。このため、ペナルティ関数法においてペナルティ係数を小さい値から  $\infty$  まで増加させることは、 $R_{cp}$  を小さい値から 1 を超えた値まで増加させることに対応することになる。本研究では、 $R_{cp}$  を集団における実行可能解の割合に応じて動的に制御する方法について考察する。

### 3.3 制約優先度の制御

一般に、集団中の全個体の実行可能であれば、目的関数値の最適化を重視すべきであると考えられる。逆に全個体の実行不能であれば、制約の最適化を重視すべきである。したがって、目的関数の最適化と制約の最適化を重視する度合いは実行可能個体の割合で決めることが適当であると考えられる。

本研究では、実行可能個体の割合である  $R_{feasible}$  に基づき、以下のように  $R_{cp}$  を決定する。

$$R_{cp} = R_{cp}^0 + (1 - R_{cp}^0)(1 - R_{feasible}) \quad (12)$$

$$R_{feasible} = \frac{|\{\mathbf{x}_i | \phi(\mathbf{x}_i) = 0\}|}{|P|} \quad (13)$$

パラメータ  $R_{cp}^0$  ( $0 \leq R_{cp}^0 \leq 1$ ) の推奨値は 0.5 である。このとき、全個体の実行可能である場合は  $R_{cp} = 0.5$  となり、目的関数と制約の最適化を同程度に行うことになる。全個体の実行不可能な場合は  $R_{cp} = 1$  となり、制約の最適化を優先して行うことになる。

## 4 提案手法

本研究では集団的降下法として、差分進化 (Differential Evolution, DE) を採用し、DE に等価ペナルティ法を導入した DEEPC (DE with Equivalent Penalty Coefficient method for constrained optimization) を提案する。

### 4.1 差分進化

差分進化は Storn and Price [21,22] によって提案された進化的アルゴリズムである。DE は確率的な直接探索法であり、解集団を用いた多点探索を行う。DE には幾つかの形式が提案されており、DE/base/num/cross という記法で表現される。“base” は基本ベクトルとなる親の選択方法を指定する。例えば、DE/rand/num/cross は基本ベクトルのための親を集団からランダムに選択し、DE/best/num/cross は集団の最良個体を選択する。“num” は基本ベクトルを変異させるための差分ベクトルの個数を指定する。“cross” は子を生成するために使用する交叉方法を指定する。例えば、DE/base/num/bin は一定の確率で遺伝子を交換する交叉 (binomial crossover) を用い、DE/base/num/exp は、指数関数的に減少する確率で遺伝子を交換する交叉 (exponential crossover) を用いる。

### 4.2 提案手法のアルゴリズム

提案手法のアルゴリズムは以下の通りである。

**Step0** 初期化。  $N$  個の初期個体  $\mathbf{x}_i$  を探索空間内に生成し、初期集団  $P = \{\mathbf{x}_i | i = 1, 2, \dots, N\}$  を構成する。全ての個体を評価する。

**Step1** 終了判定。終了条件を満足すれば、アルゴリズムは終了する。終了条件としては、最大関数評価回数を用いる。

**Step2** 子個体の生成。以下の操作を全個体  $\mathbf{x}_i$  に対して  $i = 1, 2, \dots, N$  の順で行う。3 個体  $\mathbf{x}_{r1}, \mathbf{x}_{r2}, \mathbf{x}_{r3}$  を  $\mathbf{x}_i$  および互いに重複しないようにランダムに選択する。変異ベクトル  $\mathbf{m}_i = \mathbf{x}_{r1} + F(\mathbf{x}_{r2} - \mathbf{x}_{r3})$  を生成する。変異ベクトル  $\mathbf{m}_i$  と親個体  $\mathbf{x}_i$  に指数交叉を適用し、子個体  $\mathbf{x}_i^{\text{child}}$  を生成する。個体を評価し、 $f(\mathbf{x}_i^{\text{child}})$  と  $\phi(\mathbf{x}_i^{\text{child}})$  を求める。

**Step4** ペナルティ係数の決定。条件式 (5) を満足しないトレードオフ関係にある個体の EPC 値 ( $\rho_i$ ) を式 (7) で求め、リスト  $\{\rho_i\}$  を昇順にソートする。式 (12) で  $R_{cp}$  を求め、式 (8) で  $\rho_t$  を求め、式 (11) に基づきペナルティ係数  $\rho(t)$  を決定する。

**Step5** 生存者選択. 各子個体と親個体を順に比較するために, その個体と子個体の拡張目的関数値を求める. 拡張目的関数値を比較し, 子ベクトル  $x_i^{\text{child}}$  が親ベクトルよりも良ければ子ベクトルが生存者となり, 親を子ベクトルで置換する.

**Step6** Step1 に戻る.

### 4.3 実験条件

本研究では, DE に関するパラメータは, 個体数  $N=20$ ,  $F = 0.7$ ,  $CR = 0.9$  とした. 制約優先度  $R_{cp}$  は,  $R_{cp}^0 = 0.5$  として, 実行可能個体の割合  $R_{feasible}$  に基づいて制御した. 目的関数の最大評価回数  $FE_{\max}$  を 2,500 回, 5,000 回, 10,000 回の 3 通りの場合について実験を行った. 各問題について 30 回独立に試行を行い, 各試行における最良個体の目的関数値を求めた. ただし, 最良個体とは, 制約逸脱度が最小の個体であり, 制約逸脱度が同じ場合は目的関数値が最小の個体である.

### 4.4 Himmerblau の問題

Himmerblau 問題の定義を図 1 に示す. 表 1 に実験結果を示す. 各アルゴリズムによる試行中の最良値, 平均値, 最悪値および標準偏差を示した.  $\epsilon$ DE は文献 [16] に, それ以外は文献 [23] に基づく結果である.  $\epsilon$ DE は  $\epsilon$  制約法を DE に導入したアルゴリズム, MGA は多目的 GA と解の優越関係によるアルゴリズム, Gen は遺伝的アルゴリズムを利用したアルゴリズム, GRG は Generalized Reduced Gradient 法, Death は death penalty 法, その他はペナルティに基づくアルゴリズムであり, ペナルティ係数を固定する static penalty, 探索ステップ数によりペナルティ係数を変化させる dynamic penalty, simulated annealing のように温度によりペナルティ係数を変化させる annealing penalty, 複数の探索点の状態によりペナルティ係数を決定する adaptive penalty, 解の集団と 2 種類のペナルティ係数のための集団を用いて共進化させる Coevolutionary penalty 法である.

良い結果を示したアルゴリズムは DEEPC と  $\epsilon$ DE である. DEEPC と  $\epsilon$ DE は関数評価回数が 2,500 回の時点で他の全てのアルゴリズムより全ての項目において優れている. DEEPC と  $\epsilon$ DE を比較すると, 関数評価回数 2,500 回における DEEPC の最悪値が評価回数 5,000 回における  $\epsilon$ DE の最良値よりも優れており, DEEPC の方が  $\epsilon$ DE よりも探索効率が優れていると考えられる.

### 4.5 角材の溶接の設計

角材の剪断応力 ( $\tau$ ), 曲げ応力 ( $\sigma$ ), 台の座屈荷重 ( $P_c$ ), 角材の端のたわみ ( $\delta$ ) などの制約の元でコストが最小となる角材の溶接を設計する. 図 3 のように, 4 つの決定変数  $h(x_1)$ ,  $l(x_2)$ ,  $t(x_3)$ ,  $b(x_4)$  により設計する.

この問題の定義を図 2 に示す.

表 2 に実験結果を示す. 良い結果を示したアルゴリズムは DEEPC と  $\epsilon$ DE である. DEEPC と  $\epsilon$ DE は関数評価回数が 2,500 回の時点で他の全てのアルゴリズムより全ての項目において優れている. DEEPC と  $\epsilon$ DE を比較すると, 評価回数 2,500 回において最良値と平

均値は DEEPC の方が優れおり, 最悪値は  $\epsilon$ DE の方が優れているが, その差は小さい. 評価回数 5,000 回においては平均値と最悪値が  $\epsilon$ DE の方が優れているが, その差は小さい. したがって, DEEPC と  $\epsilon$ DE はほぼ同等の性能であると考えられる.




Fig. 3: Welded beam design

### 4.6 圧力容器の設計

半球状のキャップが両端に付いている円筒状の容器において, 材料, 形成, 溶接に必要なコストを最小化する問題である. 図 5 に示すように,  $T_s$  (シエルの厚み),  $T_h$  (キャップの厚み),  $R$  (内径),  $L$  (円筒状の長さ) の 4 変数を設計する. このうち,  $T_s$  と  $T_h$  は利用可能な筒状鋼板の厚みから, 0.0625 インチの整数倍である.

この問題の定義を図 4 に示す.




Fig. 5: Pressure vessel design

表 3 に実験結果を示す. Deb は Genetic Adaptive Search, Kannan は拡張 Lagrangian Multiplier 法, Sandgen は Branch and Bound 法によるものである.

良い結果を示したアルゴリズムは DEEPC と  $\epsilon$ DE である. DEEPC と  $\epsilon$ DE は関数評価回数が 2,500 回の時点で他の全てのアルゴリズムより標準偏差以外の全ての項目において優れている. DEEPC は関数評価回数が 2,500 回の時点で標準偏差以外の項目で  $\epsilon$ DE 以外のアルゴリズムより優れている. DEEPC と  $\epsilon$ DE を比較すると, 関数評価回数 2,500 回において, DEEPC は全ての項目において  $\epsilon$ DE より優れているため, DEEPC の方が探索効率が低いと考えられる.

## 5 あとがき

制約付き最適化問題を制約なしの問題に変換するペナルティ関数法に対して, 等価ペナルティ係数法を提案し, 集団的降下法において EPC 値に基づきペナルティ係数を動的に制御する方法を提案した. 本研究では, 提案手法を差分進化に適用した DEEPC を構成した. DEEPC により幾つかの代表的な制約付き最適化問題を解き, 他の手法を比較することにより, DEEPC

$$\begin{aligned} & \text{Minimize } f(\mathbf{x}) = 5.3578547x_3^2 + 0.8356891x_1x_5 + 37.293239x_1 - 40792.141 \\ & \text{Subject to } g_1(\mathbf{x}) = 85.334407 + 0.0056858x_2x_5 + 0.00026x_1x_4 - 0.0022053x_3x_5, \\ & \quad g_2(\mathbf{x}) = 80.51249 + 0.0071317x_2x_5 + 0.0029955x_1x_2 + 0.0021813x_3^2, \\ & \quad g_3(\mathbf{x}) = 9.300961 + 0.0047026x_3x_5 + 0.0012547x_1x_3 + 0.0019085x_3x_4, \\ & \quad 0 \leq g_1(\mathbf{x}) \leq 92, 90 \leq g_2(\mathbf{x}) \leq 110, 20 \leq g_3(\mathbf{x}) \leq 25, \\ & \quad 78 \leq x_1 \leq 102, 33 \leq x_2 \leq 45, 27 \leq x_3, x_4, x_5 \leq 45. \end{aligned}$$

Fig. 1: Himmerblau's problem

Table 1: Result of Himmerblau's problem

Algorithm	FEs	Best	Average	Worst	S.D.
DEEPC	2,500	<b>-31025.5242</b>	<b>-31025.4031</b>	<b>-31025.1229</b>	<b>0.0946</b>
	5,000	<b>-31025.5602</b>	<b>-31025.5600</b>	<b>-31025.5581</b>	<b>0.0004</b>
	10,000	<b>-31025.5602</b>	<b>-31025.5602</b>	<b>-31025.5602</b>	<b>0.0000</b>
εDE	2,500	-31011.7391	-30979.3300	-30925.7070	20.4843
	5,000	-31025.0348	-31023.8356	-31018.9192	1.2120
	10,000	-31025.5601	-31025.5579	-31025.5490	0.0022
MGA	5,000	-31005.7966	-30862.8735	-30721.0418	73.240
Gen		-30183.576	N/A	N/A	N/A
GRG		-30373.949	N/A	N/A	N/A
Co-evolutionary	900,000	-31020.859	-30984.2407	-30792.4077	73.6335
Static	5,000	-30790.2716	-30446.4618	-29834.3847	226.3428
Dynamic	5,000	-30903.877	-30539.9156	-30106.2498	200.035
Annealing	5,000	-30829.201	-30442.126	-29773.085	244.619
Adaptive	5,000	-30903.877	-30448.007	-29926.1544	249.485
Death	5,000	-30790.271	-30429.371	-29834.385	234.555

Table 2: Result of welded beam problem

Algorithm	FEs	Best	Average	Worst	S.D.
DEEPC	2,500	<b>1.7260</b>	<b>1.7335</b>	1.7439	0.0047
	5,000	1.7249	1.7250	1.7254	0.0001
	10,000	1.7249	1.7249	1.7249	0.0000
εDE	2,500	1.7267	1.7339	<b>1.7423</b>	<b>0.0039</b>
	5,000	1.7249	<b>1.7249</b>	<b>1.7250</b>	<b>0.0000</b>
	10,000	1.7249	1.7249	1.7249	0.0000
MGA	5,000	1.8245	1.9190	1.9950	0.05377
Co-evolutionary	900,000	1.7483	1.7720	1.7858	0.01122
Static	5,000	2.0469	2.9728	4.5741	0.6196
Dynamic	5,000	2.1062	3.1556	5.0359	0.7006
Annealing	5,000	2.0713	2.9533	4.1261	0.4902
Adaptive	5,000	1.9589	2.9898	4.84036	0.6515
Death	5,000	2.0821	3.1158	4.5138	0.6625

の有効性を示した。

今後は、 $R_{cp}$ の制御およびアルゴリズムパラメータである $R_{cp}^0$ についてさらに考察するとともに、本手法を様々なアルゴリズムに適用し、その性能を調べることを予定している。

謝辞 本研究は、JSPS 科研費 26350443, 17K00311 の助成を受けて行われた。

## 参考文献

- 1) Z. Michalewicz: "Genetic algorithms, numerical optimization and constraints", Proc. of the 6th International Conference on Genetic Algorithms, Pittsburgh, pp. 151–158 (1995).
- 2) Z. Michalewicz: "A survey of constraint handling techniques in evolutionary computation methods", Proc. of the 4th Annual Conference on Evolutionary Programming, The MIT Press, Cambridge, Massachusetts, pp. 135–155 (1995).
- 3) Z. Michalewicz and M. Schoenauer: "Evolutionary algorithms for constrained parameter optimization problems", Evolutionary Computation, **4**, 1, pp. 1–32 (1996).

- 4) J. Kennedy and R. C. Eberhart: "Particle swarm optimization", Proc. of IEEE International Conference on Neural Networks, Perth, Australia, pp. 1942–1948 (1995).
- 5) Y. Shi and R. Eberhart: "A modified particle swarm optimizer", Proc. of IEEE International Conference on Evolutionary Computation, Anchorage, pp. 69–73 (1998).
- 6) J. Kennedy and R. C. Eberhart: "Swarm Intelligence", Morgan Kaufmann, San Francisco (2001).
- 7) K. E. Parsopoulos and M. N. Vrahatis: "Particle swarm optimization method for constrained optimization problems", Intelligent Technologies — Theory and Application: New Trends in Intelligent Technologies (Eds. by P. Sincak, J. Vascak and et al.), Vol. 76 of Frontiers in Artificial Intelligence and Applications, IOS Press, pp. 214–220 (2002).
- 8) K. Deb: "An efficient constraint handling method for genetic algorithms", Computer Methods in Applied Mechanics and Engineering, **186**, 2/4, pp. 311–338 (2000).
- 9) T. P. Runarsson and X. Yao: "Stochastic ranking for constrained evolutionary optimization", IEEE Trans. on Evolutionary Computation, **4**, 3, pp. 284–294 (2000).
- 10) 高濱, 阪井: "制約付き非線形最適化手法  $\alpha$  制約法によるファジー制御ルールの最適化", 電子情報通信学会論文誌, **J82-A**, 5, pp. 658–668 (1999).
- 11) 高濱, 阪井: " $\alpha$  制約 simplex 法によるファジー制御ルールの学習", 電子情報通信学会論文誌, **J83-D-I**, 7, pp. 770–779 (2000).
- 12) 高濱, 阪井: " $\alpha$  制約遺伝的アルゴリズム  $\alpha$ GA による制約付き最適化", 電子情報通信学会論文誌, **J86-D-I**, 4, pp. 198–207 (2003).
- 13) T. Takahama and S. Sakai: "Constrained optimization by the  $\alpha$  constrained particle swarm optimizer", Journal of Advanced Computational Intelligence and Intelligent Informatics, **9**, 3, pp. 282–289 (2005).
- 14) T. Takahama and S. Sakai: "Constrained optimization by applying the  $\alpha$  constrained method to the nonlinear simplex method with mutations", IEEE

Minimize  $f(\mathbf{x}) = 1.10471x_1^2x_2 + 0.04811x_3x_4(14 + x_2)$   
Subject to  $g_1(\mathbf{x}) = \tau(\mathbf{x}) - \tau_{max} \leq 0$ ,  $g_2(\mathbf{x}) = \sigma(\mathbf{x}) - \sigma_{max} \leq 0$ ,  $g_3(\mathbf{x}) = x_1 - x_4 \leq 0$ ,  
 $g_4(\mathbf{x}) = 0.10471x_1^2 + 0.04811x_3x_4(14 + x_2) - 5 \leq 0$ ,  $g_5(\mathbf{x}) = 0.125 - x_1 \leq 0$ ,  
 $g_6(\mathbf{x}) = \delta(\mathbf{x}) - \delta_{max} \leq 0$ ,  $g_7(\mathbf{x}) = P - P_c(\mathbf{x}) \leq 0$ ,  $0.1 \leq x_1, x_4 \leq 2, 0.1 \leq x_2, x_3 \leq 10$ ,  
where  

$$\tau = \sqrt{\tau'^2 + 2\tau'\tau''\frac{x_2}{2R} + \tau''^2}, \tau' = \frac{P}{\sqrt{2x_1x_2}}, \tau'' = \frac{MR}{J}, M = P\left(L + \frac{x_2}{2}\right),$$

$$R = \sqrt{\frac{x_2^2 + (x_1 + x_3)^2}{4}}, J = 2\sqrt{2}x_1x_2\left(\frac{x_2^2}{12} + \frac{(x_1 + x_3)^2}{4}\right),$$

$$\sigma(\mathbf{x}) = \frac{6PL}{x_4x_3^2}, \delta(\mathbf{x}) = \frac{4PL^3}{Ex_3^3x_4}, P_c(\mathbf{x}) = \frac{4.013E\sqrt{x_3^2x_4^6/36}}{L^2}\left(1 - \frac{x_3}{2L}\sqrt{\frac{E}{4G}}\right),$$

$$P = 6000lb, L = 14in, \delta_{max} = 0.25in, E = 30 \times 10^6psi, G = 12 \times 10^6psi,$$

$$\tau_{max} = 13600psi, \sigma_{max} = 30000psi.$$

Fig. 2: Wedled beam design problem

Minimize  $f(\mathbf{x}) = 0.6224x_1x_3x_4 + 1.7781x_2x_3^2 + 3.1661x_1^2x_4 + 19.84x_1^2x_3$   
Subject to  $g_1(\mathbf{x}) = -x_1 + 0.0193x_3 \leq 0$ ,  $g_2(\mathbf{x}) = -x_2 + 0.00954x_3 \leq 0$ ,  
 $g_3(\mathbf{x}) = -\pi x_3^2x_4 - 4\pi/3x_3^3 + 1296000 \leq 0$ ,  $g_4(\mathbf{x}) = x_4 - 240 \leq 0$ ,  
 $x_1, x_2 = 0.0625i, i \in \{1, 2, \dots, 99\}, 10 \leq x_3, x_4 \leq 200$ .

Fig. 4: Pressure vessel problem

Table 3: Result of pressure vessel problem

Algorithm	FEs	Best	Average	Worst	S.D.
DEEPC	2,500	<b>6059.9059</b>	<b>6067.8816</b>	<b>6094.6364</b>	<b>9.3731</b>
	5,000	<b>6059.7143</b>	<b>6060.7430</b>	6090.5274	<b>5.5308</b>
	10,000	6059.7143	<b>6060.7414</b>	6090.5262	<b>5.5309</b>
$\epsilon$ DE	2,500	6060.5071	6087.7730	6131.0306	18.7853
	5,000	6059.7144	6065.8780	<b>6090.5266</b>	12.3242
	10,000	6059.7143	6065.8767	6090.5262	12.3248
MGA	50,000	6069.3267	6263.7925	6403.4500	97.9445
Deb		6410.3811	N/A	N/A	N/A
Kannan		7198.0428	N/A	N/A	N/A
Sandgen		8129.1036	N/A	N/A	N/A
Co-evolutionary	900,000	6288.7445	6293.8432	6308.1497	7.4133
Static	$2.5 \times 10^6$	6110.8117	6656.2616	7242.2035	320.8196
Dynamic	$2.5 \times 10^6$	6213.6923	6691.5606	7445.6923	322.7647
Annealing	$2.5 \times 10^6$	6127.4143	6660.8631	7380.4810	330.7516
Adaptive	$2.5 \times 10^6$	6110.8117	6689.6049	7411.2532	330.4483
Death	$2.5 \times 10^6$	6127.4143	6616.9333	7572.6591	358.8497

- Trans. on Evolutionary Computation, **9**, 5, pp. 437–451 (2005).
- 15) 高濱, 阪井: “ $\epsilon$  制約遺伝的アルゴリズムによる制約付き最適化”, 情報処理学会論文誌, **47**, 6, pp. 1861–1871 (2006).
  - 16) T. Takahama, S. Sakai and N. Iwane: “Solving nonlinear constrained optimization problems by the  $\epsilon$  constrained differential evolution”, Proc. of the 2006 IEEE Conference on Systems, Man, and Cybernetics, pp. 2322–2327 (2006).
  - 17) T. Takahama and S. Sakai: “Fast and stable constrained optimization by the  $\epsilon$  constrained differential evolution”, Pacific Journal of Optimization, **5**, 2, pp. 261–282 (2009).
  - 18) T. Takahama and S. Sakai: “Constrained optimization by the  $\epsilon$  constrained differential evolution with an archive and gradient-based mutation”, Proc. of the 2010 IEEE Congress on Evolutionary Computation, pp. 1680–1688 (2010).
  - 19) E. Camponogara and S. N. Talukdar: “A genetic algorithm for constrained and multiobjective optimization”, 3rd Nordic Workshop on Genetic Algorithms and Their Applications (3NWGA) (Ed. by J. T. Alander), Vaasa, Finland, University of Vaasa, pp. 49–62 (1997).
  - 20) P. D. Surry and N. J. Radcliffe: “The COMOGA method: Constrained optimisation by multiobjective genetic algorithms”, Control and Cybernetics, **26**, 3, pp. 391–412 (1997).
  - 21) R. Storn and K. Price: “Minimizing the real functions of the ICEC’96 contest by differential evolution”, Proc. of the International Conference on Evolutionary Computation, pp. 842–844 (1996).
  - 22) R. Storn and K. Price: “Differential evolution – A simple and efficient heuristic for global optimization over continuous spaces”, Journal of Global Optimization, **11**, pp. 341–359 (1997).
  - 23) C. A. C. Coello: “Theoretical and numerical constraint-handling techniques used with evolutionary algorithms: A survey of the state of the art”, Computer Methods in Applied Mechanics and Engineering, **191**, 11–12, pp. 1245–1287 (2002).



# ロボット"CATARO"を使った被介護者の異常検知

○田中竜二, 大島千佳, 中山功一 (佐賀大学)

## Detecting Abnormal Condition Using a Robot "CATARO"

\* R. Tanaka, C. Oshima and K. Nakayama (Saga University)

**Abstract**— Caregivers in a nursing facility are too busy to pay attention to a lot of care receivers constantly. In this paper, we proposed a monitoring robot that informs the care receivers' bad condition to the caregivers. A smartphone which includes a system was attached to the robot's eyes. The system detected that the care receivers lose the balance of the seated posture by image recognition using deep learning. Moreover, the system can track a care receiver's face region and identify who is a front of the robot as well as have a conversation with the care receiver.

**Key Words:** Open pose, Face Detector, Face++

### 1 はじめに

近年, ニュースや新聞などで Deep Learning が話題になっている。Deep Learning の発達は著しく, 2017 年には, Google が Tensorflow を使用したオブジェクト検出 API を, Microsoft が顔検出として Face API をリリースした。それらは, 無料公開されており, 現在研究が盛んである。本研究では, 介護施設で, 施設を利用する高齢者 (以下「被介護者」) が, 手工芸や色塗りなどの作業を行っている場面での不調を知らせる Deep Learning を使った見守りロボットシステムを提案する。ここでいう不調とは, 特定の時間内での悪い姿勢への変化や, 日常的には見られない体勢への変化に表れる疲れや飽きを指す。

実現に向けた課題の1つ目として, 人の姿勢をシステムが学習する際に, 通常の画像認識では服装や背景などが邪魔をして学習がうまくできないことが挙げられる。解決する方法として“Open Pose<sup>1)</sup>”と呼ばれる手法を利用する。Open Pose とは, 国際学会 CVPR2017 (Conference on Computer Vision and Pattern Recognition) で発表された手法であり, 様々な服装や背景であっても, リアルタイムに人の体の特徴点の座標や関節の位置を求めることができる。Open Pose で得られた2次元座標を Deep Learning を用いて判定させることができれば, 1 つめの課題は解決するのではないかと考える。

課題の2つ目として, Open Pose を用いるために監視カメラを設置すると, 被介護者は監視をされていると感じ, 心理的に非常にストレスになる。そこで, 人形型の見守りロボットにカメラを搭載し, 監視されていると感じさせないようにできると考える。

本研究では, 見守りロボットに, 見守り機能 (顔追従/顔識別/会話), 異常検知機能 (姿勢検知/異常推定), 通報機能の実装をする。本稿では, このうちの見守り機能と異常検知機能について述べる。



Fig. 2: A robot, "CATARO."




Fig. 2: The internal structure of CATARO



Fig. 3: The framework of CATARO.

### 2 見守りロボットとシステム概要

Fig.1 に完成した見守りロボット “CATARO<sup>2)3)</sup>” の

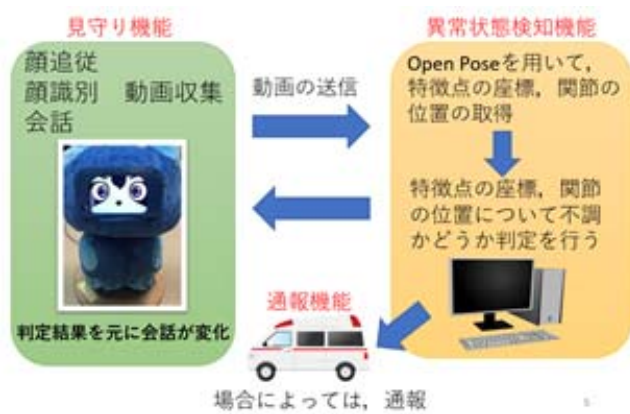


Fig. 4 Setup of System

外観, Fig.2, Fig.3 に, それぞれ内部構造, 骨格を示す. 顔部分には, 3つの機能をまとめた Android アプリケーション<sup>4)</sup>をインストールしたスマートフォンを配置する. 開発環境は Android Studio を, 言語は Java を用いる. 体の部分には, サーボモーターが2つ内蔵されており (Fig. 2), Bluetooth 接続された Android アプリケーションと通信する. 体部分の材料としては, 木質成型板 (MDF) /プラスチックダンボール/ポリ乳酸 (PLA) を使用している. MDF とプラスチック段ボールはレーザカッターで加工し, PLA は 3D プリンタで加工している. 外側にぬいぐるみ素材のカバー (服) を着せている.

Fig.4 にシステムの全体像を示す. 本研究では, 介護施設を想定し, 見守りロボットが利用者の不調を発見し, 通報することを目的とする. そのため, 見守り機能, 異常検知機能, 通報機能を1つのシステムとしての実装を目指す.

まず, 見守りロボットの異常状態検知機能では, 収集した動画に, Open Pose を用いて特徴点の座標, 関節の位置の取得を行う. それぞれの値について Deep Learning を用いて, 姿勢検知, 異常推定を行う. 通報機能では, 姿勢検知, 異常推定で得られた結果によって, 見守りロボットが被介護者に状態に合わせた会話をしたり, 介護スタッフに発話で知らせたり, スマートフォンに通知したり, また医療機関等に通報したりする予定である.

### 3 見守り機能

見守り機能として実装した, 顔追従/顔識別/会話の3つの機能について述べる.

#### 3.1 顔追従

顔を追従するために, Google が提供している API の Face Detector<sup>5)</sup>を使用した. 上下左右 (首を振る角度は, 正面を中心とすると上下左右 120°程度), 被験者の顔を四角で囲む. それと同時に, 四角で囲んだ顔の



Fig. 5: CATARO's facial expression (normal).




Fig. 6: Visualization of Face Detector.



Fig. 7: CATARO's facial expression (smile).

中心座標と画面の中心座標との角度を Bluetooth 接続された体部分に送信する.

Fig.5 に, 顔追従のスマートフォン・アプリケーションの通常の画面を示す. 画面の左上に設置されている切り替えボタンを押すことにより, Fig. 6 に示すように, Face Detector の状態を可視化して確認できる. 表示している情報としては, 笑顔の度合いと目の開き具合である. 被介護者の笑顔度が 0.8 以上を超えると, Fig.7 で示すように, CATARO は笑顔を返す. よって被介護者は, よりリラックスして作業に望める.

#### 3.2 顔識別

Megvii Technology Limited が提供している API の Face++<sup>6)</sup>を使用する. Fig.6 の左下のボタン「音声切替」を押すと, 音声入力が始まる. 「初めまして」と画面に向かって声をかけると, Fig.8 に示す登録画面に移行する. 登録画面では, まず顔の写真を3枚撮影する. その後, 音声によって, 名前を入力し, 登録を完了させる.

再び音声切替のボタンを押し, 「こんにちは」と画面に向かって声をかけると, Fig.9 に示す検索画面に移行する. 検索画面では, 顔の写真を1枚撮影する. そ




Fig. 8: Registration screen.



Fig. 9: Search screen.



Fig. 10: An example of their conversation.

の後、登録された顔のうち、撮影した顔と一致する顔があるかどうか判断する。一致する顔写真があった場合、CATAROの目の位置にあるスマートフォンから、その顔に紐づけられている名前で「〇〇さん、こんにちは」と返す。登録された顔写真の中に、撮影した顔と一致する写真がなかった場合には、「登録されていない顔です」と返す。

### 3.3 会話

日常会話の応答機能は、A3RTが提供しているTalk API<sup>7)</sup>を使用する。音声の入出力には、Googleが提供しているAPIのSpeech Recognizerを使用する。Fig.6の左下の「音声切替」ボタンを押し、音声入力を開始する。利用者の発話に対して、日常的な会話を返す。たとえば、Fig.10に示すように、「天気がいいですね」と問いかけると、CATAROから「明日も晴れるといいですね」と音声で返ってくる。これにより、利用者は、CATAROとコミュニケーションを取ることができる。利用者は、リラックスした状態で作業に臨める。



Fig. 11: An example of posture detecting by the Open Pose




Fig. 12: Coordinate points for detecting posture.

以上により、利用者の近くに、CATAROを設置し、自然な形で利用者を監視できる。

## 4 異常検知機能

### 4.1 Open Pose のプログラム

異常検知機能では、Open Poseを用いる。Open Poseとは、Deep Learningを用いて、人物のポーズを可視化する手法である。静止画や動画など複数人物がいても検出することが可能である。リアルタイムで人の体の特徴点の座標、関節の位置を求めることができる。Fig. 11は、Open Poseを用いたサンプルである。オプションとして顔や手のひらの詳細な特徴点の座標を求めることもできる。本稿では、求めた座標点に対して、Deep Learningを用いて、姿勢の判定を行う。それにより、服装や背景等に関係なく学習をすることができる。またDeep Learningには、Tensorflow上で動くライブラリのKeras<sup>8)</sup>を使用する。

### 4.2 姿勢判定

本稿では、着席している利用者を想定した姿勢の判定を行う。Fig.13~15で示す3種類(通常状態、ストレッチ状態、前屈状態)の姿勢で、それぞれ0~2のラベルを付ける。訓練データは、9000個(約5分)ずつの計27000個使用する。テストデータは、リアルタイムで300個(約10秒)ずつの計900個取得する。一番高い予測確率である判定結果をログ形式で出力する。



9000 個の訓練データから無作為に 200 個を選び、それぞれのラベル (0~2) に分類されるかを学習する。次に、残りの 8800 個から無作為に 200 個を選び、それぞれのラベルに分類されるかを学習する。この流れを、9000 個の訓練データ全て学習に使用するまで繰り返し、それを 1 エポックとする。これを 100 回~1000 回まで 100 回間隔で行う。Table 1 は、学習を行った後の正答率と、その平均を示す。通常状態と前屈状態の平均がそれぞれ 97% であるが、ストレッチ状態の平均が 91% であった。その理由として、ストレッチ状態は、通常状態と前屈状態を合わせているような姿勢であるため、正解が分かれたのではないかと考える。




Fig. 13: Posture (normal)




Fig. 14: Posture (stretching)



Fig. 15: Posture (bending forward)

Table 1: Result of the experiment.

エポック数	100	200	300	400	500
通常状態	0.96	0.96	0.96	0.96	0.96
ストレッチ状態	0.89	0.9	0.9	0.9	0.91
前屈状態	0.98	0.96	0.98	0.97	0.96

600	700	800	900	1000	平均
0.96	0.97	0.97	0.98	0.97	0.97
0.9	0.9	0.91	0.91	0.9	0.9
0.99	0.97	0.96	0.96	0.98	0.97

## 5 今後の課題と展望

本稿では、見守りロボット“CATARO”の機能として Android アプリケーションによる見守り機能の作成と、異常検知機能を構築した。見守り機能では、顔追従、顔識別、会話の 3 つのサブ機能を付けたが、顔識別と会話に関しては、まだ自発的に行わなければいけないという課題もあり、見守りロボットの方から会話を提供することができれば、より違和感なく作業ができるのではないかと考える。異常検知機能として Deep Learning を用いて被験者の姿勢の判定を行った。異常検知機能では、学習データを十分に得ることができ、姿勢を全て 90% 以上判定することができた。現在、PC でリアルタイムの判定はできるが、将来的には、CATARO が動画を PC に送信し、その動画を受信した PC が判定を行う。その後、判定結果を CATARO の Android アプリケーション側に送信し、見守りロボットの会話などを変化させる必要がある。

## 参考文献

- 1) GitHub – CMU-Perceptual-Computing-Lab/openpose : <https://github.com/CMU-Perceptual-Computing-Lab/openpose>
- 2) Patrick Hock, Chika Oshima, Koichi Nakayama: CATARO: A Robot that Tells Caregivers a Patient’s Current Non-Critical Condition Indirectly, Proceedings of the Genetic and Evolutionary Computation Conference, 1841/1844(2018).
- 3) 大島 千佳, Patrick Hock, 中山 功一: CATARO: 介護者

に被介護者の状態を気づかせるロボット, 情報処理学会アクセシビリティ研究会, **2018-AAC-7**, 3(2018).

- 4) Android Developers :  
<https://developer.android.com/reference/android/media/FaceDetector>
- 5) Face API で顔検出を試してみる :  
<https://qiita.com/droibit/items/ec0ce34a0ad5e34593e5>
- 6) Face++ Cognitive Services :  
<https://www.faceplusplus.com/>
- 7) Talk api : <https://a3rt.recruit-tech.co.jp/product/talkAPI/>
- 8) Keras/Tensorflow で始めるディープラーニング入門 :  
<https://qiita.com/yampy/items/706d44417c433e68db0d>



# 複数 Android 端末の分散制約充足アルゴリズムによる協調

○田川来夏 上田俊 (佐賀大学)

## Distributed Constraint Satisfaction Among Android Devices

\*K. Tagawa and S. Ueda (Saga University)

**Abstract**— A constraint satisfaction problem (CSP) has widely studied in AI literature, where the aim of this problem is to find an assignment of values to variables that satisfies all constraints. A distributed CSP (DisCSP) is a CSP where variables and constraints are distributed among agents. Various application problems in multi-agent systems can be formalized as DisCSPs. Asynchronous Backtracking (ABT) algorithm have been developed for solving a DisCSP in distributed manner. In this paper, we implement ABT algorithm as an Android application, which we call ABT on Androids. We evaluate our application by solving a 2-queens problem.

**Key Words:** DisCSP, Multi-agent Systems

### 1 はじめに

マルチエージェントシステムとは、複数の自律的なエージェントが存在する環境での社会システムを設計・分析する研究分野であり、長く人工知能の一分野として研究されている。近年のネットワーク環境やスマートフォンといったデジタル通信機器の処理能力の向上から、この分野の研究成果の現実問題への応用が期待されている。分散制約充足問題は、伝統的な制約充足問題の変数と制約を複数エージェントに分散させた問題であり、人工知能における様々な応用問題に適用可能であるとして、長年研究されている。

$N$ -Queens 問題は分散制約充足問題として定式化可能な典型的な問題例である。この問題は  $N \times N$  のサイズのチェス盤に  $N$  個のクイーンを互いに打ち合わないよう配置する問題である。チェスにおけるクイーンは、将棋の飛車と角を組み合わせたように、縦・横・ななめに移動できる。4-Queens 問題では、Fig. 1 のようにクイーンを配置することで互いに打ち合わないよう配置できる。

ほとんどの制約充足問題のためのアルゴリズムが、分散制約充足問題を解くために、分散・非同期に拡張可能であり、非同期バックトラッキングアルゴリズムといった様々なアルゴリズムが提案されている。

本論文では、非同期バックトラッキングアルゴリズムを Android アプリケーションとして実装する。このアプリケーションを ABT on Androids と呼び、Android 端末で分散制約充足問題を解くことを目標とする。分散制約充足問題の従来研究では、エージェント同士の通信方式はアブストラクトにモデル化されている。そのため、ABT on Androids の開発では、モデル化されたネットワーク通信に合致するように Android 間通信を実装する必要がある。Android 間の通信方式はいくつか考えられるが、本研究では、実装が容易な TCP/IP を用いて実装する。本論文では、開発した ABT on Androids を Android スマートフォンにインストールし、動作確認の第 1 段階として 2-Queens 問題を解くことを試みた。

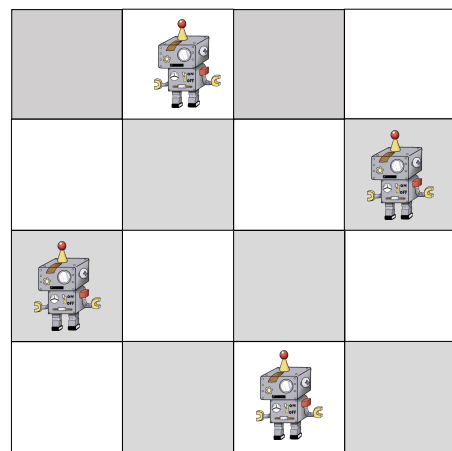


Fig. 1: 4-Queens problem

### 2 分散制約充足問題

#### 2.1 制約充足問題

制約充足問題 (Constraint Satisfaction Problem, CSP) <sup>1)</sup> とは、有限で離散的な領域から値をとる複数の変数に、制約を満たす値を割り当てる問題である。スケジューリング問題やプランニング問題をはじめ、人工知能の様々な問題が制約充足問題により定式化できることが知られている。制約充足問題は以下で定義される:

- $n$  個の変数  $x_1, x_2, \dots, x_n$ ,
- 上記の変数に対する領域  $D_1, D_2, \dots, D_n$ ,
- 直積  $D_{k_1} \times \dots \times D_{k_j}$  に対する制約  $p_k(x_{k_1}, x_{k_2}, \dots, x_{k_j})$ .

変数  $x_i$  の値が  $d_i \in D_i$  であることを  $(x_i, d_i)$  と表記する。制約充足問題の解は、すべての制約を満たす変数の値の組 (充足可) か、そのような組が存在しない (充足不能) かのいずれかである。

**例 1 (4-Queens 問題)** 4-Queen 問題を制約充足問題として定式化する。それぞれの行 (または列) にはひとつのクイーンしか置けないことは明らかなので、それぞれが各行のクイーンの位置を表す 4 つの変数  $x_1, x_2, x_3, x_4$

で盤面を表現できる。変数の領域は、 $D_1 = D_2 = D_3 = D_4 = \{1, 2, 3, 4\}$  である。クイーンが互いに取合わないようになる制約は、例えば、変数  $x_i$  と  $x_j$  に対して、

$$x_i \neq x_j \wedge |i - j| \neq |x_i - x_j|$$

と表現できる。例えば、 $x_2$  と  $x_4$  に対しては、 $x_2 \neq x_4 \wedge |x_2 - x_4| = 2$  という制約が設定される。この制約がすべての変数の組に対して存在する。この制約充足問題に対して、変数の値の組、 $\{(x_1, 2), (x_2, 4), (x_3, 1), (x_4, 3)\}$  はすべての制約を満たす。すなわち、4-Queen 問題は充足可能な問題である。

## 2.2 分散制約充足問題

分散制約充足問題 (Distributed Constraint Satisfaction Problem, DisCSP)<sup>2)</sup> とは、制約充足問題における変数および制約が複数のエージェントに分散された問題である。各エージェントは自身の持つ変数に値を割り当てようとするが、異なるエージェントのもつ変数との間にも制約があり、そのような制約も満たす必要がある。本研究では、エージェントの持つ変数はひとつとし、記述の簡略化のため、必要に応じて両者を区別せずに用いる。また、エージェント間の通信モデルとして、以下を仮定する:

- エージェント間通信はメッセージ通信によってなされる。
- エージェントは、他のエージェントのアドレスを知っている場合に限り、そのエージェントにメッセージを送信できる。
- 任意のふたつのエージェントの組合せに関して、送信されたメッセージの順序は保存される。

例えば、例 1 を分散制約充足問題として定式化する場合、ひとつのエージェントがひとつのクイーンの位置を操作し (対応する変数を持ち)、メッセージ通信によって、すべての制約を満たす値の割当を探索する。

分散制約充足問題を解くアルゴリズムは、(集中型の) 制約充足問題を解くアルゴリズムを、分散・非同期型に拡張したものが多い。代表的なバックトラッキングアルゴリズムや反復改善法を拡張したアルゴリズムが提案されている。また、アルゴリズムの表現を単純にするために、以下の仮定を置いているものもある:

1. 各エージェントの持つ変数は唯一である。
2. エージェント間の制約はすべて二項関係 (binary) である。
3. 各エージェントは自分に属する変数が関係する制約をすべて知っている。

## 2.3 非同期バックトラッキングアルゴリズム

非同期バックトラッキング (Asynchronous Back-Tracking, ABT) アルゴリズム<sup>3)</sup> は、バックトラッキングアルゴリズムを分散・非同期に動作できるよう拡張したアルゴリズムである。各エージェントは以下の 2 種類のメッセージを用いる:

- (**ok?**,  $(x_j, d_j)$ ): 変数  $x_j$  の値が  $d_j$  であることを伝えるメッセージ。
- (**nogood**,  $x_j, V$ ): 新たに発生した nogood  $V$  を伝えるメッセージ。ここで、nogood  $V$  は制約違反を起こす値の組合せである。例えば nogood  $V = \{(x_i, d_i), (x_j, d_j)\}$  は、 $(x_i, d_i)$  と  $(x_j, d_j)$  が制約に違反していることを表す。

ABT では、各エージェントの識別子に従って優先順位が設定される。**ok?**メッセージは優先順位の高いエージェントから低いエージェントに、割り当てた値を知らせる目的で送られる。逆に、**nogood**メッセージは優先順位の低いエージェントから高いエージェントに、現在の値の割当では制約を充足できないことを知らせる目的で送られる。

以下に、ABT での各エージェントの動作の概要を示す。詳細は文献<sup>3)</sup>等を参照されたい。

- エージェントは **ok?**メッセージを受信すると、**agent\_view** に他のエージェントの値の割当を記録する。
- エージェントは **nogood**メッセージを受信すると、受信した nogood  $V$  を制約に追加する。
- いずれかのメッセージを受信するたびに、**agent\_view** に記録されている値の割当と制約を考慮し、自身の変数の値を割り当てる。
  - いずれの制約にも違反しない場合、優先度の低いエージェントに **ok?**メッセージを送信する。
  - どの値を割り当てても制約に違反する場合、優先度の高いエージェントに **nogood**メッセージを送信する。

いずれかのエージェントが空の nogood  $V = \emptyset$  を受信した場合、その問題は充足不可能 (すべての制約を満たす値の組が存在しない) であることを表す。問題が充足可能である場合、すべてのエージェントがなんらかの値を割り当て、新たなメッセージを送らない安定した状態に落ち着く。このときに各エージェントによって割り当てられている値の組が解となる。

## 3 Android 端末

Android は Google により開発・提供されているスマートフォンやタブレット端末向けのオペレーティングシステムである。Android 端末では様々な API が提供されており、Android SDK ツールを用いてデータやリソースとともに、ソースコードを APK (Android パッケージ) にコンパイルできる。最新安定版は 2018 年 8 月 6 日にリリースされた 9.0 Pie である。

### 3.1 Android 間通信

Android 端末では、電話回線による通信に加えて様々な通信方式を利用できる。以下に、Android で利用可能な通信方式をまとめる:

Wi-Fi Android は無線 LAN 接続でインターネットに接続できる。Android API では、HTTP (HTTPS) でサーバと通信する機能や、相手の IP アドレスと

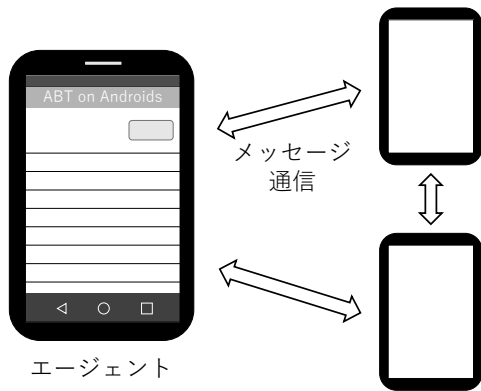


Fig. 2: Overview

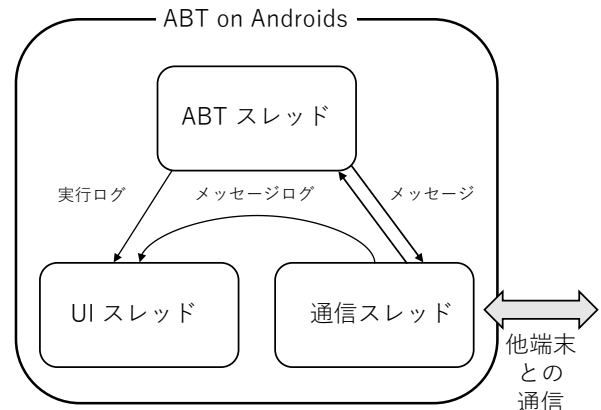


Fig. 3: Application design

ポート番号を指定してソケット通信を行う機能が提供されてる。

**Bluetooth** Bluetooth API は、API Level 5 で導入されており、ワイヤレスヘッドホンやカーステレオシステムと接続できる。当然、Android 端末同士の接続も可能であり、P2P 接続が可能である。

**Wi-Fi peer-to-peer** Wi-Fi peer-to-peer は、ルーターやアクセスポイントといった中継機器を介すことなく、端末同士で P2P 接続を行う通信方式である。Android 4.0 (API Level 14) で導入された比較的新しい機能である。Bluetooth より速く、より遠い距離でも通信できるとされている。

## 4 ABT on Androids

本論文では、非同期バックトラッキングアルゴリズムを Android アプリケーションとして実装した ABT on Androids を開発する。ABT on Androids では、Android 端末で起動したアプリケーションがエージェントとして動作し、他の Android 端末とメッセージ通信を行いながら非同期バックトラッキングアルゴリズムを実行する (Fig. 2)。

### 4.1 アプリケーション設計

ABT on Androids は、以下の 3 つのスレッドで構成される (Fig. 3):

**UI スレッド** アプリケーションの画面表示を担当する。他のスレッドの状態を監視するとともに動作ログの表示を行う。

**通信スレッド** 他の Android 端末との通信を担当する。Android アプリケーションでは、通信のような重い処理は画面表示を行うスレッドとは別スレッドで動作させなければならない。同じスレッドで通信処理を行おうとすると、NetworkOnMainThread-Exception が発生しアプリケーションが強制終了する。

**ABT スレッド** 非同期バックトラッキングアルゴリズムを実行する。受信したメッセージを通信スレッドから受け取り、メッセージを送信するときは通信スレッドを通して他端末に送信する。

### 4.2 通信方式

ABT on Androids では、すべての Android 端末が Wi-Fi によってひとつのプライベートネットワークに接続されていることを仮定する。Android 端末同士の通信は TCP/IP 方式で行われ、IP アドレス (とポート番号) を指定したソケット通信によって行う。

3.1 章で述べた通り、Android 端末では、Bluetooth および Wi-Fi peer-to-peer による通信も可能だが、本研究での実装は行わなかった。理由として、以下が挙げられる:

- 端末同士のペアリング等、通信開始までに煩雑な前処理が必要であり、それらをアプリケーション内に実装しなければならない。
- 通信が不安定で、途中で通信が切断されるだけでなく、端末同士の発見ができない場合がある。

一方で、無線 LAN 接続による通信は安定しており、実装も容易である。より具体的には、Wi-Fi によるプライベートネットワークへの接続は Android OS によって設定でき、ネットワーク検出やアドレス取得といった処理をアプリケーション内で実装する必要がない。また、ソケット通信の API は容易に利用でき、IP アドレスとポート番号だけを指定すれば通信できる。そのため、すべての端末を同一のプライベートネットワークにあらかじめ接続しておき、アプリケーションにその情報を記録しておくことで、端末同士の通信が可能となる。

Bluetooth および Wi-Fi peer-to-peer による通信の利点は、Android 端末以外のネットワーク設備が必要ない点である。今後の応用を考慮するとこの利点は無視できず、これらの通信方式の実装は今後の課題である。

## 5 検証

開発した ABT on Androids を Android 端末にインストールし動作確認を行った。検証には 2 台の Android 端末を使用し、2-Queens 問題を解くことを行った。

2-Queens 問題の変数とその領域は以下である:

変数  $x_1, x_2$

変数の領域  $D_1 = D_2 = \{1, 2\}$

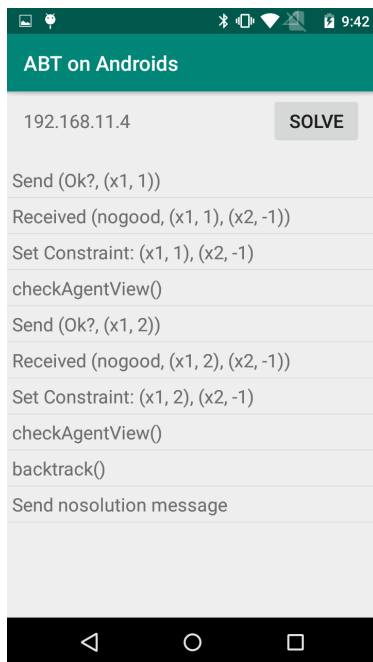


Fig. 4: Execution result:  $x_1$

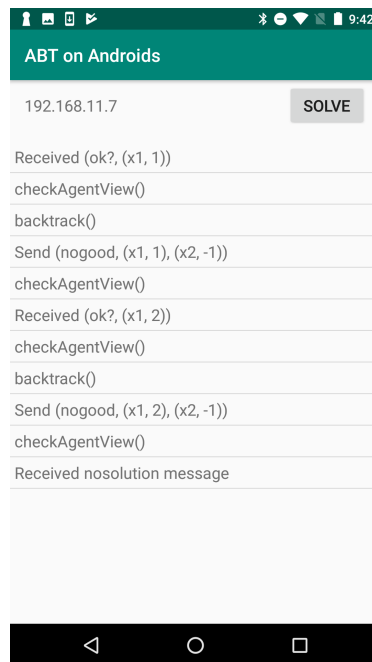


Fig. 5: Execution result:  $x_2$

また、以下の2つの制約が存在する:

- $x_1 \neq x_2$
- $|x_1 - x_2| \neq 1$

上記の制約より、すべての変数の値の組がいずれかの制約に違反するため、2-Queens問題は充足不能である。例えば、 $\{(x_1, 1), (x_2, 1)\}$ の割当は一つの制約に違反し、さらに、 $\{(x_1, 2), (x_2, 1)\}$ の割当は二つの目の制約に違反する。従って、ABT on Androidsが空の **nogood** を生成して停止すれば、正しく動作することが確認できる。

今回の検証では、以下のAndroid端末を使用した:

- エージェント  $x_1$   
モデル JCI VA-10J  
Androidバージョン 5.0.2
- エージェント  $x_2$   
モデル Nexus 5X  
Androidバージョン 7.1.1

それぞれの端末での実行結果を Figs. 4, 5 に示す。以下、今回の実行結果を順に確認する。なお、開発途中のため、メッセージや制約に関して、ログの表示方法と論文内の記法が一致しない箇所があることを断っておく。まず、 $x_1$  が自身に 1 を割り当て、 $x_2$  に (**ok?**,  $(x_1, 1)$ ) を送信する。この **ok?** メッセージを受信した  $x_2$  は、割り当て可能な値を `checkAgentView()` を用いて探索する。しかし、1 と 2 のいずれの値を割り当てても制約に違反するため、`backtrack()` を呼び出し、 $x_1$  に (**nogood**,  $x_1, (x_1, 1)$ ) を送信する。次に、 $x_1$  は **nogood** メッセージを受信したため、自身の値を 2 に変更し、再度  $x_2$  に (**ok?**,  $(x_1, 2)$ ) を送信する。同様に、 $x_2$  は `checkAgentView()` を呼び出して値を探索するが、制約に違反しない値の組が存在しないため、 $x_1$  に (**nogood**,  $x_1, (x_1, 2)$ ) を送信する。こ

の **nogood** メッセージを受信した  $x_1$  は、`backtrack()` を実行し別の値を割り当てようとするが、1 と 2 のいずれの値も **nogood** として記録されているため、自身の変数に値を割り当てることができない。つまり、空の **nogood** が生成されるため、この問題が充足不能であることがわかる。最後に、 $x_1$  は上記を知らせる特殊なメッセージである **nosolution** メッセージを  $x_2$  に送信し、停止する。同様に、 $x_2$  も **nosolution** メッセージを受信し、停止する。以上で、 $x_1$  と  $x_2$  で動作している ABT on Androids が停止するため、2-Queens問題が充足不能であることが本アプリケーションでも確認できた。

## 6 おわりに

本論文では、分散制約充足問題を解く非同期バックトラッキングアルゴリズムを Android アプリケーションとして実装した、ABT on Androids を開発した。また、開発したアプリケーションを Android スマートフォンにインストールし、2-Queens問題を解くことでアプリケーションの検証を行った。

今後の課題として、TCP/IP 以外の通信方式によるエージェント間通信の実装や、3 台以上の Android 端末での動作確認が挙げられる。

## 参考文献

- 1) A. K. Mackworth. : Constraint satisfaction, Encyclopedia of Artificial Intelligence, 285/293, John Wiley & Sons, (1992)
- 2) 横尾真, エドモンド H. ダーフィ, 石田亨, 桑原和宏 : 分散制約充足による分散協調問題解決の定式化とその解法, 電子情報通信学会論文誌, Vol. J-75 D-I, No. 8, 704/713 (1992).
- 3) M. Yokoo and K. Hirayama : Algorithms for distributed constraint satisfaction: A review, Journal of Autonomous Agents and Multi-agent Systems, 3(2), 189/211 (2000).



# 交通事故時の移動モード判別アルゴリズムの実装

○塚本安記規, 大島千佳, 中山功一 (佐賀大学)

## Implement an Algorithm that Estimates Transportation Mode at Autonomous Traffic Accident

\* A. Tsukamoto, C. Oshima and K. Nakayama (Saga University)

**Abstract**— Lots of vulnerable road users are killed in traffic accidents in rural area with small population because execution timing of accident notifications are delayed. I developed an application that detects abnormalities and reports the traffic accident to a fire department based on a value from an acceleration sensor of a smartphone. However, a threshold value of the acceleration sensor to judge the traffic accident is different according to a transportation mode of the user. In this paper, I constructed a transportation mode classifier using a deep learning technique. The results of the experiment showed that the classifier could judge two kinds of transportation mode, walking, or bicycle correctly in 30 minutes.

### 1 はじめに

安全装置が次々と開発され、自動車に実装されている。一方、歩行者や自転車などの交通弱者に対する安全装置は少ない。そのため、被害者が意識を失うような交通事故が起きた場合、通報が遅れたために被害者が亡くなる場合もある。この問題を解決するために、交通事故にあった交通弱者を助けるシステムが必要になると考える。また、交通事故が起きたとき、目撃者や物的証拠が少ない場合に、正しく事故状況を判断することが難しい。

これまでの研究では、事故を検知し、自動で仲介サーバにはGPSデータを送り、同時に病院には加速度データとGPSデータを送るスマートフォンアプリ（以下、従来アプリと表記する）の開発を行った。また、ドローンと連携して、事故現場に救助隊が到着する前に現場の状況を確認できるシステムを提案した。これにより、交通事故の発生を検知できるようになった。また、交通事故の発生位置をサーバに送信し、ドローンが交通事故現場上空まで自動飛行して事故発生後の状況をドローンのカメラ映像から遠隔地でも把握できるようになった。一方、事故発生直前の被害者の状況は、検知できていない。交通事故が起きたとき、歩行しているのか、自転車に乗っているのか、などの状態によって、事故の大きさが変わってくる。例えば、自転車に乗っていた被害者が、進行方向に対し右側から強い衝撃を受けて15メートル飛ばされた、などの状況が検知できれば、より早く正確な救命活動に取り掛かれる可能性がある。

そこで本研究では、従来アプリを改良し、事故発生前後の加速度情報/音声情報/位置情報/速度情報などを取得し、送信できるようにする。また、ディープラーニングを用いて、加速度データから事故発生時の移動モードを判別する分類器を構築する。ここでのモードは、停止、歩行、自転車、自動車の4種類とする。

### 2 交通事故の検知・通報アプリの改良

#### 2.1 誤検知防止機能

##### 2.1.1 誤検知防止機能の説明

従来アプリでは、加速度の推移から事故を検知している。しかし、スマートフォンを落として強い衝撃を与えられたときに事故と誤検知する場合があった。スマートフォンは落としやすく、落とす度に事故と検知しては、開発したアプリを使ってもらえない。そこで、誤検知防止機能を追加する。そのために、スマートフォンを落としたときの加速度の変化を調べる必要がある。そこで、落下実験を行う。

##### 2.1.2 落下実験

実験方法は、スマートフォンを高さ1mからソファベッドに落下させる。これを2回行う。図2.1は、そのときの加速度の変化である。




図2.1 落下時の加速度

スマートフォンが、ソファベッドに落下したときを0秒とする。通常使用時はいずれかの方向の重力加速度を検知しているが、赤枠部分であるソファベッドに落下する直前は、加速度が0m/s<sup>2</sup>になっていることが分かる(無重力状態)。その後、重力加速度の4~8倍の加速度を検知していることが分かる。

##### 2.1.3 誤検知防止機能の仕組み

落下実験より、スマートフォンを落としたときは、衝突前に無重力状態になることが分かった。交通事故



の場合は、衝突前に無重力状態になることはない。そこで、強い加速度を検知する前に、無重力状態が0.1秒継続した場合は、誤検知と判断するように改良する。これにより、スマートフォンを落とした場合は、事故と判断されることが無くなると予測される。

### 2.1.4 誤検知防止機能の確認実験

誤検知防止機能が正しく動作しているか確認するために、2つの実験を行う。

1つ目の実験は、スマートフォンを様々な方法で落下させる。この実験の目的は、どのような落とし方をしても事故と判断されないか確認するためである。結果は、様々な方法で落下させた全てにおいて、事故と判断されなかった。そのときの3パターンについて、加速度の変化をグラフにしたものを載せる。図2.2は、高さ2mからスマートフォンの画面を上に向けて落とした場合である。図2.3は、高さ1.5mからスマートフォンの画面を横に向けて落とした場合である。図2.4は、高さ1mから画面を上向きにしてスマートフォンを軽く前に投げながら落とした場合である。




図2.2 高さ2m画面上向きからの落下




図2.3 高さ1.5m画面横向きからの落下




図2.4 高さ1m画面上向きから前方に落下

図2.2～図2.4の赤枠部分に注目すると、落下する直前は、無重力状態になっていることが分かる。スマート

フォンを落とした場合は、落下する直前に無重力状態があるので、誤って事故と判断することはない。

2つ目の実験は、衝突実験である。実験方法は、バイクと乗用車の衝突、自転車と乗用車の衝突である(図2.5～図2.8)。このとき、バイク、自転車に乗せたダミー人形の腰にスマートフォンを設置した(図2.9、2.10)。



図2.5 衝突実験で使用するバイク



図2.6 バイクと乗用車の衝突後の画像



図2.7 衝突実験で使用する自転車



図2.8 自転車と乗用車の衝突後の画像



図2.9 バイクに設置したスマートフォン



図2.10 自転車に設置したスマートフォン

実験の目的は、誤検知防止機能を追加しても、正しく事故と判断されるか確認するためである。結果は、のべ4台のスマートフォンのうち、4台とも事故検知に成功した。そのときの2台のスマートフォンに注目して、加速度の変化をグラフにしたものを載せる。図2.11は、バイクと乗用車を衝突させたときの加速度の変化をグラフ化したものである。図2.12は、自転車と乗用車を衝突させたときの加速度の変化をグラフ化したものである。グラフの横軸について、衝突したときを0秒とする。




図2.11 バイクと乗用車の衝突

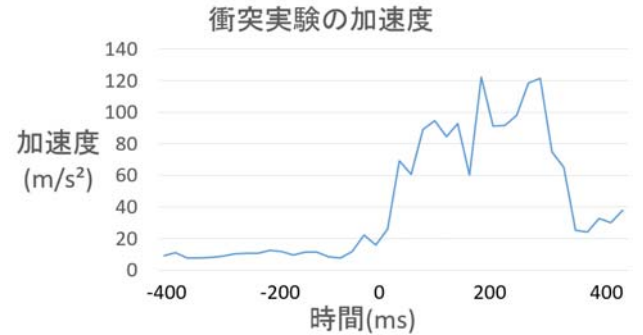


図2.12 自転車と乗用車の衝突

図2.11, 2.12より、衝突前に無重力状態になっていることはないので、正しく事故と判断される。

2つの実験より、誤検知防止機能が正しく動作していることが分かる。

### 3 事故状況保存のための従来アプリの改良

#### 3.1 スマートフォンの内部ストレージへの保存

従来アプリでは、加速度やGPSデータをメールで送信していた。この方法では、インターネットが繋がらない場合に、データを保存することができない。

そこで、スマートフォンの内部ストレージに保存する方法に改良する。仕組みは、csvファイルを作成し、加速度やGPSデータを書き込む。そのcsvファイルを内部ストレージに保存する。これにより、インターネットが繋がらない場合でも、データを保存することができる。

#### 3.2 加速度データの保存

加速度は、事故が起きたときに、衝撃の強さや速度などを推定することができる。

従来アプリは、事故前の加速度データしか保存することができなかった。事故前の加速度データだけでは、衝撃の強さや速度などを推定することが難しい。そこで、事故後の加速度も保存できるようにする。また、加速度データおよびGPSデータに時刻を付与し、より正確な情報を得る。

#### 3.3 音声データの保存

音声は、事故が起きたときに、急ブレーキ音や事故

現場での会話などを聞くことができる。事故から少し時間が経ち、警察の人が事故状況を聞くと、事故を起こした両者の意見が食い違ったり、嘘をつくことが多々ある。事故時の音声を保存しておくことにより、この食い違いや嘘を見抜ける可能性も出てくる。そこで、音声データを保存できるようにする。

### 3.4 通報不要なデータの保存

通報不要なデータとは、スマートフォンが事故とは判断しないが、少し強い加速度を検知したときのデータである。これは、小さな事故を対象としている。小さな事故を起こしたときに、通報をしない人がある。後になって、その事故が警察沙汰になったときの証拠となる。また、データを蓄積することにより、どこで小さな事故が起こるのか把握できる。そこで、通報する事故データとは別に、通報不要なデータを保存できるようにする。

### 3.5 改良したアプリの動作確認

事故状況を保存するための上記4点の改良について、動作確認を行った。3.1節、3.2節、3.3節で述べた事故発生時に保存するデータについては、いずれも事故を検知した場合に、正しく記録されることを確認した(図3.1, 図3.2, 図3.3)。3.4節で述べた通報不要なデータの保存については、事故とは判別されない程度の少し強い加速度を加えると、通報されずにデータが保存されていた(図3.4)。いずれも、正しく動作し、目的のデータが保存されていることを確認した。




図 3.3 音声データの保存




図 3.4 通報不要なデータの保存



図 3.1 内部ストレージへの保存




図 3.2 加速度データの保存

## 4 衝突実験による動作確認

### 4.1 実験の目的と方法

実験の目的は、第3章で追加した事故状況保存システムが、動作確認である。実験方法は、自転車(図4.1)と乗用車の衝突である。これを2回行う。1回目の実験は、走行中の自転車と乗用車の衝突である。このとき、自転車に乗せたダミー人形の腰にスマートフォンを設置した(図4.2)。2回目の実験は、停止させた自転車と乗用車の衝突である。このとき、自転車のかごにスマートフォンを設置した(図4.3)。



図 4.1 衝突させる自転車





図 4.2 腰にスマートフォンを設置



図 4.3 かごにスマートフォンを設置

## 4.2 実験結果

結果は、2 回の実験ともに正しく事故を検知し、内部ストレージへの保存、加速度データの保存、音声データの保存に成功した。衝突後の加速度に特徴的な変化が見つかったので説明する。

図 4.4, 4.5 は、1 回目と 2 回目の実験の加速度の変化をグラフ化したものである。衝突時の時間を 0 秒とする。




図 4.4 腰に設置したスマートフォンの加速度の変化




図 4.5 かごに設置したスマートフォンの加速度の変化

赤枠に注目すると、2 回の実験において、衝撃時と衝突してから約 1 秒後に強い加速度を検知している。

ここでは、2 回の衝突実験の結果しか記載していないが、他の衝突実験においても、似たような結果となった。

## 4.3 考察

4.2 節より、スマートフォンを身に付けても、身に付けずにかごに入れたとしても、正しく事故を検知することが分かる。また、交通事故が起きたときに、衝撃時と衝突してから約 1 秒後に強い加速度を検知することが分かる。現段階では、この結果を用いた機能はないが、この結果を用いることにより新しいことができると考える。1 つのアイデアとして、これから多くのデータを集め、ディープラーニングで学習させることにより、どのような事故が起きたのか判別できる分類器を構築できると考える。

## 5 ディープラーニングを用いたモード判別用の分類器

### 5.1 モード判別用の分類器

交通事故が起きたとき、歩行しているのか、自転車に乗っているのか、などの状態によって、事故の大きさが変わってくる。そこで、ディープラーニングを用いて、モード判別用の分類器を構築する。ここでのモードは、停止、歩行、自転車、自動車の 4 種類である。

本研究では、加速度のデータを活用し、分類器を構築する。

### 5.2 開発環境

本研究で使用する開発環境を表 5.1 に示す。

表 5.1 開発環境

分類	詳細
ライブラリ	Tensorflow, Keras
実行環境	Jupyter notebook
開発言語	Python

### 5.3 データ取得方法

ディープラーニングを用いた分類器を構築するためには、多くのデータが必要となる。そこで、データを取得するアプリを作成した(図 5.1)。このアプリは、初めにモードを選択してから画面左下のボタンをタップすることでデータの取得が始まる。そして、選択したモードに対応するラベルと x 軸, y 軸, z 軸それぞれの加速度を保存する。



図 5.1 データ取得アプリ

## 5.4 学習用データ

学習用データは、停止、歩行、自転車、自動車の 4 つのデータを使う。停止のデータは、スマートフォンを様々な向きに置き、合計 4 時間のデータを集めた。歩行のデータは、被験者を 4 人集め、各 1 時間ずつの合計 4 時間のデータを集めた。自転車のデータは、歩行のデータと同じ被験者 4 人で、各 1 時間ずつの合計 4 時間のデータを集めた。自動車のデータは、歩行のデータの被験者とは異なる被験者を 2 人集め、各 2 時間ずつの合計 4 時間のデータを集めた。この学習用データを用いて、分類器を構築する。

## 5.5 試験用データ

試験用データは、4 つのモードを順不同かつ連続で 5 分ずつ集め、これを連続で 2 回行う(合計 40 分)。そして、被験者を 4 人集め、合計 2 時間 40 分のデータを集めた。集めたデータの時間は、多少前後する。この試験用データを用いて、構築した分類器に分類させる。

## 5.6 実験

### 5.6.1 実験の目的と方法

実験の目的は、2 つある。1 つ目は、どのくらいの割合で正しいモードと判断されるかである。2 つ目は、モードを切り替えたときに、どのくらいの時間で正しいモードと判断できるかである。

実験方法は、試験用データを 10 秒毎に切り分け、その 10 秒のデータを 1 つのサンプルとし、それぞれを分類器に分類させる。この試験データのサンプル数は、停止が 187 個、歩行が 257 個、自転車が 204 個、自動車が 284 個である。

### 5.6.2 実験結果

初めに、試験用データを分類器に分類させたときの各モードの正解率について結果を述べる。表 5.2 は、各モードの正解サンプル数である。図 5.2 は、各モードの正解率をグラフにしたものである。

表 5.2 各モードの正解サンプル数

モード	正解サンプル数	正解率
停止	187個中71個	38%
歩行	257個中248個	97%
自転車	204個中172個	84%
自動車	284個中44個	15%




図 5.2 各モードの正解率

停止と正しく判断されたサンプル数は 187 個中 71 個で、割合は 38% である。歩行と正しく判断されたサンプル数は 257 個中 248 個で、割合は 97% である。自転車と正しく判断されたサンプル数は 204 個中 172 個で、割合は 84% である。自動車と正しく判断されたサンプル数は 284 個中 44 個で、割合は 15% である。

次に、モードを切り替えたときに、正しいモードと判断されるまでに必要な時間をまとめたものについて述べる(表 5.3)。ここでは、歩行と自転車についてだけ考える。理由は、歩行と自転車は高い確率で正しく分類でき、停止と自動車は正しく分類できたと言いがたい結果になったからである。

表 5.3 正しいモードと判断されるまでの必要時間

	10秒	20秒	30秒
歩行	4回	2回	2回
自転車	4回	3回	1回

5.5 節で述べたように、各モードの切り替わりは、それぞれ合計 8 回ある。歩行は、10 秒で判断されたのが 4 回、20 秒で判断されたのが 2 回、30 秒で判断されたのが 2 回である。自転車は、10 秒で判断されたのが 4 回、20 秒で判断されたのが 3 回、30 秒で判断されたのが 1 回である。モードが切り替わってから 30 秒あれば、歩行と自転車は、100% の割合で正しく判断される。

### 5.6.3 考察

本研究で構築した分類器では、歩行と自転車は正しく分類できるが、停止と自動車は正しく分類できないといえる。そこで、停止と自動車の判別は、GPS を用いることにより解決できると考える。停止は移動距離がないが、自動車は移動距離が長くなるので、正しく判別できることは明らかである。

また、モードを切り替えたときに、正しいモードと



判断されるまでに必要な時間は、長くても 30 秒である。30 秒以内に正しいモードと判断されるのであれば、素早いモード判断ができていると考える。

これらのモードの判別と素早いモード判断を行うことにより、交通事故が起きたときに、どのような状態で事故にあったのかを推定することができる。また、正面衝突や横からの衝突、けが人の重症度といった事故の状況や規模などを考慮したデータを集め、分類器に活用することにより、どのような状態で、どの程度の事故で、どの程度の被害が出たのかを推定できると考える。より詳細に推定することにより、助からなかった命が助かるようになると考える。

## 6 おわりに

### 6.1 まとめ

本研究では、交通事故の検知・通報アプリの改良と事故状況判別システムの開発、分類器の構築と検証を行った。交通事故の検知・通報アプリの改良では、誤検知防止機能の追加をした。事故状況判別システムでは、内部ストレージへの保存、加速度データの保存、音声データの保存、通報不要なデータの保存を追加した。分類器の構築と検証では、ディープラーニングを用いて、分類器を構築し、その分類器が歩行と自転車において正確であることを検証した。

### 6.2 今後の課題と展望

今後の課題としては、構築した分類器をオンラインで活用することである。現段階では、オフラインでモードを判別している。交通事故の検知・通報アプリでこの分類器を有効活用するためには、オンラインでなければならない。また、この分類器は、他にも様々な使い方があると考える。今後は、この分類器をどのように活かしていくのか考える必要がある。

## 謝辞

本研究は、公益財団法人タカタ財団：研究助成プログラムの支援を受けたものである。また、衝突実験では警察庁：科学警察研究所の大賀涼様に多大なるご協力をいただいた。この深謝の意を表す。

## 参考文献

- 1) 塚本安記規 “交通弱者のためのスマートフォンを用いた交通事故の検知・通報アプリの研究開発” 2016 年度卒業論文
- 2) 角 亮憲 “ドローンを用いた事故状況の確認システムの研究開発” 2016 年度卒業論文
- 3) 中山 功一, 大島 千佳, 阪本 雄一郎 “スマートフォンアプリによる事故の自動通報とドローンによる事故状況の確認システム” , 第 39 回佐賀救急医学会, 2016
- 4) 菊池 由紀 “自転車事故の自動通報アプリの作成” 2015 年度卒業論文
- 5) Google マップ <<https://www.google.co.jp>>
- 6) 田原 誠太郎 “緊急車両の移動経路の状況把握を支援するドローンシステムの開発” 2017 年度卒業論文
- 7) 内山 彰, 勝田 悦子, 上嶋 裕紀, 山口 弘純, 東野 輝夫 “都市区画における GPS 衛星の見通し判定を用い

- 8) “た位置精度向上法の提案”, 情報処理学会論文誌, 2014  
小林 亜令, 岩本 健嗣, 西山 智 “釈迦: 携帯電話を用いたユーザ移動状態推定方式”, 情報処理学会論文誌 50(1), 193-208, 2009