

平成 29 年度 修士論文

画像と超音波を用いた
人体検出ロボットの開発

電気通信大学 大学院情報数理工学研究科

情報・ネットワーク工学専攻

情報数理工学プログラム

学籍番号 1631088

竹谷 篤也

主任指導教員 植野 真臣 教授

指導教員 川野 秀一 准教授

提出年月日 2018 年 1 月 29 日

目次

第1章	はじめに	3
第2章	先行研究	7
2.1	各種センサの比較	7
2.2	超音波による物体検出	9
2.3	超音波による人体検出	9
第3章	提案手法	12
3.1	画像センサと超音波センサ	12
3.2	人体検出口ボットの提案手法	12
3.3	ハードウェア構成	14
3.3.1	Raspberry Pi 2 Model B	16
3.3.2	超音波距離センサモジュール	17
3.3.3	画像センサモジュール	21
第4章	機械学習手法	22
4.1	2クラス分類器	22
4.1.1	決定木	22
4.1.2	ロジスティック回帰	23
4.1.3	サポートベクターマシン	24
4.1.4	Naïve Bayes	26
4.1.5	Tree Augmented Naïve Bayes	27
4.1.6	ベイジアンネットワーク	29
4.2	ニューラルネットワーク	30
4.2.1	You Only Look Once	31
第5章	超音波センサ	33
5.1	2クラス分類器別精度比較実験	33
5.1.1	実験方法	33
5.1.2	実験結果	35
第6章	画像センサ	36
6.1	検出精度実験	36
6.1.1	実験方法	36

6. 1. 2	実験結果	37
6. 2	輝度による判別精度への影響	37
6. 2. 1	実験方法	38
6. 2. 2	実験結果	39
第7章	実証実験	40
7. 1	人体検出可能距離の測定実験	41
7. 1. 1	実験方法	41
7. 1. 2	実験結果	42
7. 2	人体部位別検出精度実験	42
7. 2. 1	実験方法	42
7. 2. 2	実験結果	43
第8章	結言	45
	謝辞	47
	参考文献	48

第 1 章 はじめに

1995 年に発生した阪神・淡路大震災では、同時多発的に広範囲で発生した建物の倒壊により、瓦礫内に閉じ込められた被災者の救出が課題となった。被災者の生存率は、被災時には約 75%であるのに対し、翌日には約 24%と急激に低下した。このような背景から、災害時において人的被害を最小限にするためには、要救助者の迅速な探索と救助が必要不可欠であることがわかる。

また、この震災による被災者の死亡原因の約 77%が圧死によるものだと言われており、これは建物の倒壊に巻き込まれた被災者の多くが犠牲になったことを示唆している。素早く発見し救助できれば助かった可能性が指摘されているが、被災者がいる可能性のある瓦礫の撤去には、多くの人手と時間を要する。

この震災をきっかけに、人手のみによる救出活動には、圧倒的な人手不足に加え、余震などによる二次災害の危険、探索が困難な狭所や閉所の存在など数多くの問題があることが明確になった[1]。

そこで、これらの問題を解決するために、災害現場で人間を探索し救助することを目的とした災害救助ロボットの開発が進められてきた[2][3][4][5]。災害救助ロボットは、主に人間の探索を行うためのセンサ、センサを搭載するための移動機構、遠隔操作を行うための通信技術により構成される [6]。ロボットに搭載されるセンサには、瓦礫内など狭所での探索能力や周囲の地形や天候に影響されない優れたセンシング能力が求められる[7]。これにより搭載されるセンサも小型で周囲の環境に依存しない必要がある。

これらを踏まえ本研究では、小型で周囲の環境に影響されない優れたセンシング能力を持つ災害救助ロボットの開発を目指す。

物体を検出するセンサには数多くの種類が存在し、これまで様々な実証実験が行われてきた[8][9][10]。これにより各種センサにはそれぞれ欠点が存在することがわかってきている。そのため、災害救助ロボットに搭載されるセンサは、それぞれの欠点をカバーしあえるように複数のセンサを搭載したものが主流になりつつある。

本研究では、災害救助ロボットに搭載するセンサとして、超音波センサに着目した。超音波センサは、小型で軽量さらには安価なものが多く、周囲の環境に影響されにくいという特徴を持ち、至近距離でのセンシング能力が高い[11]。このことから超音波センサは、災害救助ロボットに求められるセンサ条件に一致していると言える。しかし、超音波センサを用いた人体検出に関する研究事例は他のセンサと比べ比較的少ない。

近年の超音波センサを搭載した人体検出に関する研究に Bhatia ら[12]の研究がある。Bhatia らは、超音波センサをベースに複数のセンサをロボットに搭載し人体を検出する手法を提案している。この手法は、超音波センサに動体を検出させ、その物体が人体か否かを他のセンサによって判別する。これは、人が動くことを前提として提案されているため、災害現場などで瓦礫に挟まれ動けない人体は検出することができないという問題がある。

そこで動いていない人体を検出する手法として Sonia ら[13]が超音波センサの反射波を用いた検出法を提案した。この手法は、超音波センサの反射波から対象物の特徴を取得し、1クラス分類器によって人体であるかを判別することができる。しかし、検出距離が固定であるという問題があり、災害救助ロボットに搭載されると仮定した場合、汎用性の高いものとは言い難い。

その問題を解決するために苗村ら[14]は、検出対象・センサ間距離を考慮した超音波人体検出法を提案している。これは、検出対象・センサ間距離と超音波の反射波から特徴量を抽出し、それぞれを説明変数とした 2 クラス分類器を用いて、その物体が人体かその他物体かを判別する。苗村らの検出手法は、検出対象・センサ間距離を固定しなくとも対象を検出可能という利点がある。しかし、この検出手法は超音波センサ 1 つだけを使用して人体を検出しようとしているため、超音波センサの欠点である測定可能距離の短さが、研究結果に大きく影響を与えている。それにより、対象との距離が大きく制限されており 30cm を超えると対象物の検出精度が著しく低下するという問題がある。また、反射波による材質情報をもとに検出を行っているため、検出可能な箇所は人体の肌が露出した顔などに限られる。災害現場など厳しい環境下において、人体の顔部分しか検出できないというのは、最適検出距離まで移動する距離や時間を考えると効率的ではない。そこで、超音波センサの欠点である測定可能距離の短さをカバーするために画像センサを採用し、これらの問題を解決することを考えた。画像センサも超音波センサと同様に、小型で軽量さらには安価なものが多いセンサである。しかし、超音波センサとは異なり測定可能距離が長いという特徴がある。

本研究では、超音波センサと画像センサを用いた新たな人体検出手法を提案し、これを実装した人体検出口ボットの開発を目的とする。提案する検出手法は、超音波センサと画像センサから同時に情報を取得し、それぞれ異なった機械学習手法を用いて人体の検出を行うものである。超音波センサからの人体検出手法は、苗村らの人体検出手法をベースに検出対象・センサ間距離と超音波の反射波から特徴量を抽出し、それぞれを説明変数とした 2 クラス分類器によ

って人体の検出を行う．画像センサからの人体検出手法は，機械学習手法の 1 つであるニューラルネットワークを活用し人体検出を行う．画像センサの検出精度実験により，ニューラルネットワークを用いた人体検出では，高い検出精度を誇ることがわかった．しかし，人体やその他物体の映り方によって誤検出も存在する．誤検出の場合，総じて検出結果の期待値が低くなるため，画像センサから人体を検出し，期待値が低い場合に限り超音波センサを用いた 2 段階検出を行う．これにより，大幅な人体検出時間の短縮と検出精度の向上が確認できた．この新たな提案手法を実装したロボットは，実証実験により，超音波センサ 1 つでは成しえなかった高い汎用性を示し，災害現場などの厳しい状況下でも周囲の環境に依存しない優れたセンシング能力を有することが確認できた．

第2章 先行研究

2. 1 各種センサの比較

災害現場で人体検出を行う場合，ロボットに搭載されるセンサには，瓦礫内など狭所での探索能力や周囲の地形や天候に影響されない優れたセンシング能力を有する必要がある．そのため，搭載されるセンサも小型で周囲の環境に依存しないセンサが求められる．物体を検出するセンサは，数多く存在しこれまで多くの検証実験が行われ報告されている．表1に各種センサの性能を比較したものを示す[15]．

表 1 各種センサの比較 (5段階)

	小型	明るさに 強い	暗闇に強 い	雨・雪・ 煙に強い	至近距離 精度	安価	色の識別	分解能	測定可能 距離
画像 センサ	5	4	1	2	2	5	5	5	5
レーザー 光	1	5	5	3	2	1	1	4	4
レーダー (電磁波)	5	5	5	5	4	5	1	3	4
超音波 センサ	5	5	5	5	5	5	1	2	1

表1より各種センサには，それぞれ利点と欠点が存在することがわかる．

画像センサは，可視光などを利用し対象物の形状などを画像データとして取得するセンサである．物体検出において多くの研究事例がある[16][17][18][19]．しかし，環境の変化に影響を受けやすく暗闇などに弱い．

レーザー光は、レーザー光を利用して物体間の距離を測定するために使用されるセンサの 1 つである。レーザー光を使用しているため通常光とは違い指向性がよく、波長が一定で単色性に優れていることが特徴である。明るさや暗闇に強く測量精度が高い。そのため、自動車分野における自動運転を支えるセンシング技術として注目を集めている[20]。光を遮る不純物である雨や雪の影響を受けやすく、センサとしても比較的高価で大型のことが多い。

レーダー（電磁波）は、マイクロ波やミリ波などを用いたセンサである。主に動体の有無を検知するために用いられることが多い[21]。マイクロ波を発射し、物体に当て、反射してきた電波の周波数と、発射した電波の周波数を比較することにより物体の動きを検出する。物体が動いている場合には、ドップラ効果により反射波の周波数が変化し、これにより物体が動いているか、静止しているかを知ることができる。レーザー光と異なり小型で安価なものが多く、至近距離からの測定精度も高いことが特徴である。

超音波センサは、超音波を対象物に向けて発信し、その反射波を受信機で受信することにより、物体の有無や物体までの距離を測定することができるセンサである。小型かつ安価で、明るさや暗闇、天候など周囲の環境の影響を受けにくいことが特徴である。主に自動車や輸送機械の障害物監視や衝突防止装置として応用されている[22][23]。

表 1 より、人体検出口ボットに求められる条件を満たすセンサとしてレーダー（電磁波）と超音波センサがあげられる。レーダー（電磁波）と超音波センサは、それぞれ電波と音波を用いて物体を検出するセンサであり、お互い波の性質を有する。そのため、センサとしての特徴も非常に似ている。しかし、超音波は、電磁波に比べ伝搬速度が遥かに遅く波長が短い。これにより計測にか

かる時間は長くなるが，至近距離での検出精度が高くなる．災害現場での人体検出では狭所や閉所が多く存在するため至近距離での検出精度が重要である．そのため本研究では，超音波センサを採用し人体検出ロボットを開発する．超音波とは音波の一種であり，音波とは空気中を伝わる波のことを指す．音波は，一般に振幅と周波数で表され，人が聞こえる周波数の範囲（可聴域）は，低い音で 20Hz，高い音で 20kHz 程度であると言われている．そして，人が聞こえないほど高い音を超音波といい，人が聞こえないほど低い音を超低周波音という．以下にこの超音波を用いた応用例について述べる．

2. 2 超音波による物体検出

超音波センサは，至近距離にある物体の有無を検出することに優れている．そのため，自動車や歩行ロボットに搭載され，障害物を検出するために活用されることが多い．これは，超音波を発信し，反射波が帰ってくるまでの時間を計測することで物体を検出する．障害物の有無を取得すると同時にその距離も算出可能なため，障害物への距離に応じた対応が可能となる[24]．

2. 3 超音波による人体検出

これまでの超音波センサの応用は，超音波センサを用いて反射波が帰ってくる時間をもとに対象物との距離を計測するためだけなものとして扱われてきた．しかし，超音波は，波の性質により反射，透過，減衰などの特徴を有し，その反射波は，対象物の材質や伝搬する媒質によって変化する．本研究では，その性質に着目し，対象物の材質情報をもとに人体を検出する．

超音波センサをベースに複数のセンサをロボットに搭載して人体検出を行った研究事例に Bhatia ら[12]の研究がある。

Bhatia らは、超音波センサ、画像センサ、温度センサ、金属センサなど複数のセンサをロボットに搭載し人体を検出する手法を提案しており、このシステムは、救助活動の他に軍事や医療の現場で活用できるとしている。具体的な人体検出手法は、まず超音波センサを使用し、動体の有無を観測する。次に動体反応を検出するとブザーが鳴り、同時にその他のセンサが起動し人体か否かを判別する。最後に人体であれば、救助隊にその位置情報を送信することで救助を行うというものである。これは、人が動くことを前提として提案されているため、災害現場などで瓦礫に挟まれ動けない被災者は検出することができないという問題がある。

Sonia ら[13]は、超音波センサの反射波を用いた人体検出法を提案した。この手法は、超音波センサの反射波から Llata ら[25]の手法に基づき、対象物の特徴量を抽出する。その特徴量を用いて、1 クラス分類器であるファジールールベース 1 クラス分類器と 1 クラスサポートベクターマシンに適用し、人体であるかを判別する。しかし、検出対象・センサ間距離が固定であるという問題があり、災害現場で災害救助ロボットに搭載されると仮定した場合、汎用性の高いものとは言い難い。

そこで苗村ら[14]は、検出対象・センサ間距離を考慮した超音波人体検出法を提案している。Sonia らの提案手法は、検出対象・センサ間距離が固定されているため超音波の特性である減衰の影響を考慮する必要がなかった。しかし、検出対象・センサ間距離が固定でない場合、距離による減衰の影響を考慮する必要がある。苗村らの手法では、検出対象・センサ間距離と超音波の反射波から

特徴量を同時に考え、それぞれを説明変数とした 2 クラス分類器を用いて、その物体が人体かその他物体かを判別する。これにより、決められた検出対象・センサ間距離でなくとも物体の判別が可能となった。しかし、この検出法は超音波センサ 1 つだけを使用して人体を検出しようとしているため、超音波センサの欠点である測定可能距離の短さが、研究結果に大きく影響を与えている。それにより、対象との距離が大きく制限されており 30cm を超えると対象物の検出精度が著しく低下するという問題がある。また、反射波による材質情報をもとに検出を行っているため、検出可能な箇所は人体の肌が露出した顔などに限られる。災害現場など厳しい環境下において、人体の顔部分しか検出できないというのは、最適検出距離まで移動する距離や時間を考えると効率的ではない。

第3章 提案手法

3. 1 画像センサと超音波センサ

本研究では、小型で周囲の環境に影響されない優れたセンシング能力を持つ人体検出ロボットの開発を目指す。これらの条件を満たすセンサとして超音波センサに着目し、その超音波センサを用いた苗村らの研究手法をもとに新たな人体検出ロボットの開発を行う。苗村らの提案手法は、検出対象との距離に制限があり、検出可能な箇所も限られるといった問題がある。瓦礫内に人体があったとしても、最適検出距離に移動できなかつたり、材質情報を取得する箇所が違えば検出できない恐れがある。そこで、超音波センサの欠点である測定可能距離の短さをカバーするために画像センサを採用し、これらの問題を解決することを考えた。画像センサも超音波センサと同様に、小型で軽量さらには安価なものが多いセンサである。しかし、超音波センサとは異なり測定可能距離が長いという特徴がある[15]。

近年では、画像データからの物体検出事例も多く報告されており、中でもニューラルネットワークを用いた物体検出手法は、飛躍的に発展を遂げている[26][27][28][29][30][31][32]。本研究では、現段階の物体検出手法の中でも高精度を誇り、速度に特化した画像検出・認識用ニューラルネットワークである You Only Look Once (YOLO) を用いて人体の検出を行う。

3. 2 人体検出ロボットの提案手法

ニューラルネットワークによる画像の物体検出は、学習済みモデルを作成するために大量の学習データを必要とし、計算コストも非常に高い。そのため、本研究では YOLO の研究開発者元からリリースされている学習済みモデルを用

いる．提案する人体検出ロボットの制御基板には，Raspberry Pi2 を使用する．超音波センサによる反射波からの特徴量を用いた 2 クラス分類程度であれば，Raspberry Pi2 でも十分に対応できる．しかし，ニューラルネットワークの場合，学習済みモデルを用いた人体検出であっても判別に多くの計算時間を要することが考えられる．そこで，画像センサから取得した情報を外部 PC に送信し，そこで YOLO による人体検出を行うことを考えた．結果を返り値として返すことで，スムーズな人体の検出が期待できる．図 1 に提案するロボットの人体検出時のフローチャートに示す．




図 1 提案する人体検出ロボットのフローチャート

提案する人体検出ロボットは，超音波センサと画像センサを用いて同時に情報を取得開始する．そして，片方のセンサで人体を検出したとき，検出終了とする．しかし，人体を検出したセンサが画像センサの場合，その期待値が低い

時に限り超音波センサの最適検出距離に移動し，超音波センサでの再検出を行う．これにより，大幅な人体検出時間の短縮と検出精度の向上が期待できる．

3. 3 ハードウェア構成

災害現場などの広範囲の探索では，分散探索が有効であることが知られている[3]．そのため，本研究で提案するロボットは安価で量産がしやすいものを目指す．以下に提案する人体検出ロボットのハードウェア構成を示す．

表 2 ハードウェア構成

本体	タミヤ工作シリーズ
制御基板	Raspberry Pi 2 Model B
温度センサモジュール	BME280
超音波距離センサモジュール	HC-SR04
画像センサモジュール	Raspberry Pi Camera Board 775-7731
通信機器	GW-USNANO2A
メモリカード	MSDAR40N16G
モータードライバ	DRV8835

本体は，タミヤの楽しい工作シリーズのトラック&ホイールセット，ツインモーターギヤーボックス，ユニバーサルプレートを使用した．これにより安価で自由度の高いロボットが作成できる．

駆動は，駆動用モーターへの電圧を変えることで，前進，後進，右旋回，左旋回，速度変更を行う．また，駆動用モーターの電源は，Raspberry Pi2 の電源と共用とし，電圧の変更は，モータードライバ（DRV8835）を使用する．

無線通信は、Wi-Fiで行う。送受信機として、Raspberry Pi2 を用いる。
Raspberry Pi2 には、無線 LAN 機能が搭載されているが、不安定なため無線 LAN アダプター（GW-USNANO2A）を使用する。

Raspberry Pi2 の電源は、充電電池 4 本（ $1.2[V] \times 4[本] = 4.8[V]$ ）で行う。
Raspberry Pi2 を制御基板としているため、PC もしくはスマートフォンでの遠隔操作が可能である。しかし、本研究では、自動で人体検出を行うのが目標の 1 つであるため遠隔での操作は行わないものとする。

本研究で開発した画像と超音波を用いた人体検出ロボットを図 2 に示す。




図 2 提案した画像と超音波を用いた人体検出ロボット

3. 3. 1 Raspberry Pi 2 Model B

提案する人体検出口ボットの制御基板として、Raspberry Pi 2 Model Bを採用した。Raspberry Pi 2 は ARM ベースの超小型コンピュータであり、2012 年にプログラミングの学習用に作られた。キャッシュカードサイズの本体にマイクロ USB 接続の電源（1.2A 以上推奨）、USB キーボード、USB マウス、ディスプレイ（HDMI 接続）、マイクロ SD カード（8GB 以上推奨）を接続することによって、PC のように様々なアプリケーションが実行可能である。プログラム言語は Python を推奨しているがその他にも様々な言語に対応している。また、無線 LAN 機能も搭載されているため遠隔での操作が可能とかなり自由度が高い。図 3 に今回使用している Raspberry Pi 2 Model B を示す。




図 3 Raspberry Pi 2 Model B

3. 3. 2 超音波距離センサモジュール

本研究で扱う超音波距離モジュール HC-SR04 は, 検出対象とセンサ間の距離及び反射波のからの特徴量を抽出する目的で使用する. 以下に仕様と端子の役割を示す.

表 3 HC-SR04 の仕様

仕様	内容
電源電圧	5V
待機電流	2mA 未満
信号出力	0-5V
センサ角度	15 度以下
測定可能距離	2cm-400cm
分解能	0.3cm

表 4 HC-SR04 の端子

ラベル	内容
Vcc	電源入力
Trig	超音波信号を送信
Echo	超音波信号を受信
GND	グラウンド (-)

動作手順について説明する. HC-SR04 の端子は, それぞれ入力電源 (Vcc), トリガー (Trig), エコー (Echo), グラウンド (GND) から構成される. また, 図 4 より左側のスピーカーが超音波発信素子 (TX), 右側のスピーカーが受信素子 (RX) である.




図 4 超音波距離センサモジュール HC-SR04

HC-SR04 は，制御基板に Trig 端子と Echo 端子を接続し，Trig に信号を送ることで動作する．例えば，Trig 端子を $10\mu\text{s}$ 以上 High にすると TX から 40kHz のパルスが 8 回送信される．Echo 端子は TX からパルスが送信され終え，その反射波を RX が受信するまでの間 High になる．検出対象とセンサ間の距離 d は Echo 端子が High になっている時間 $t[\text{s}]$ と音速 $c[\text{m/s}]$ により次式で求めることができる

$$d = \frac{ct}{2} \quad (1)$$

音速 c は伝わる媒質のもつ体積弾性率 $K[\text{N/m}^2]$ と密度 $\rho[\text{kg/m}^3]$ によって変化し，次式によって表すことができる．

$$c = \sqrt{\frac{K}{\rho}} \quad (2)$$

式 (2) から媒質によって音速は大きく変わることがわかる．特に相変化による影響は大きく，同じ物質では固体が最大で，次いで液体，気体の順となる．

また、音速は温度の影響も受けやすく、空気中の音速は、式(2)を用いて以下のような近似式で表すことができる。

$$c \approx 331.5 + 0.6T \quad (3)$$

ここで、 T は摂氏温度[°C]を表す。式(3)より音速は、摂氏温度が高いほど速くなることがわかる。この時、温度 T [°C]は温度センサモジュール BME280 により取得する。

反射波の特徴量は Llata ら[25]の手法に基づき、波形のピーク値を結んだ包絡線から算出する。包絡線からの特徴量 (A~H) 抽出は以下の手順で行う。

1. 包絡線の値を離散的にサンプリング
2. 最大となるサンプル番号 (A) と最大値 (B) を算出
3. 最大値の前後でそれぞれ 3 等分する
4. 各区画の包絡線の値の和を計算 (C~H)




図 5 特徴量 (A~H) 抽出イメージ

図 5 は反射波の特徴量 (A~H) 抽出箇所を可視化したものである. HC-SR04 では, 反射波から直接包絡線を得ることができないため, 包絡線検波回路を通す必要がる. ここでは, 苗村らが用いた包絡線検波回路をもとに反射波から包絡線を検波し特徴量を抽出する.




図 6 包絡線検波回路

図 6 は苗村らが用いた包絡線検波回路である. 図 7 ではまずスピーカーから超音波の反射波を受信する. その後, オペアンプを用いて反射波の振幅を増大させる. 最後にショットキーバリアダイオードを通し, その出力を抵抗器とコンデンサの並列回路で受けることで包絡線検波を行う.

包絡線を検波後, 特徴量を抽出するためにはアナログ入力でデータを取得する必要がある. しかし, Raspberry Pi 2 Model B には A/D コンバータが内蔵されていないためアナログ入力ピンが存在しない. そこでアナログ値を測定するために外部集積回路を利用することとした. 外部集積回路である ADS1015 を使用した 4 チャンネル 12 ビット A/D コンバータを用いて Raspberry Pi 2 Model B に包絡線の特徴量が抽出できた.

3. 3. 3 画像センサモジュール

画像センサモジュールには、Raspberry Pi 専用のカメラモジュールである Raspberry Pi Camera Board 775-7731 を採用することにした。図 7 に Raspberry Pi Camera Board 775-7731 を示す。



図 7 Raspberry Pi Camera Board 775-7731

Raspberry Pi Camera Board 775-7731 は、あらゆる Raspberry Pi コンピュータ又は Compute モジュールに接続することができ、高精細（HD）ビデオや静止画が作成可能である。以下に Raspberry Pi Camera Board 775-7731 の性能表を示す。

表 5 Raspberry Pi Camera Board 775-7731 性能表

	性能
静止画像	2592×1944
最大動画解像度	1080 p
最大フレームレート	30fps

Raspberry Pi Camera Board 775-7731 は、Python によって制御し、プログラムによって画像データを取得するタイミングや、画像データの大きさなどを自由に調節することができる。

第4章 機械学習手法

本研究では，超音波センサと画像センサから取得した情報もとに2クラス分類器とニューラルネットワークを用いて人体検出を行った．以下に実験で使した各機械学習手法の概要を示す．

4. 1 2クラス分類器

4. 1. 1 決定木

決定木（Decision tree：DT）とは木構造のグラフであり，図8のようにノードと枝（エッジ）により構成される[33]．




図8 決定木モデルの構造

決定木は，説明変数 $A = \{A_1, A_2, \dots, A_n\}$ とその値 $a = (a_1, a_2, \dots, a_n)$ の組 $\{A_1 = a_1, A_2 = a_2, \dots, A_n = a_n\}$ によって表現されたデータをクラス $c = (c_1, c_2)$ に分類することを目的とする．親ノードを持たないノードを根ノードと呼び，子ノードを持たないものを葉ノードと呼ぶ．各ノードを繋ぐ枝はその分類のもととなる特徴との結合を示す．

決定木の学習は、具体的な判断事例から決定木モデルを生成することを指す。判断事例は、 $(c_i, a_i)_{i=1}$ のようなデータで表され、このデータの集まり $(c_i, a_i)_{i=1}^n$ を訓練データと呼ぶ。学習アルゴリズムは、この訓練データを入力として受け取り、説明変数としきい値とのすべての組み合わせにおいて、評価関数により求められる値を計算し、それが最も小さい組み合わせになることを目指す。決定木に用いられる学習アルゴリズムは、評価関数の違いにより ID3, C5.0, C&RT, QUEST などがある[34]。

4. 1. 2 ロジスティック回帰

ロジスティック回帰 (Logistic regression : LR) は、 $a = (a_1, a_2, \dots, a_n)$ が与えられたときのクラス $c = (c_1, c_2)$ をそれぞれの条件付き確率をもとに算出し、分類する手法である[35]。

説明変数 $y = (y_1, y_2, \dots, y_n)$, $y \in \{0, 1\}$ ($y=1$ の場合 c_1 , $y=0$ の場合 c_2 を表す) が与えられた時、 y の事後確率は、以下の式で表される。

$$p(y = 1|a) = \pi(a) \quad (4)$$

$$p(y = 0|a) = 1 - \pi(a) \quad (5)$$

この事後確率と説明変数をモデル化したものをロジスティック回帰モデルと呼び、この変換方法をロジット変換と呼ぶ。以下にその式を示す。

$$\pi(a) = \frac{\exp(\beta_0 + \beta^T a)}{1 + \exp(\beta_0 + \beta^T a)} \quad (6)$$

この時、パラメータ (β_0, β) は最尤推定法によって求めることができる。

式(4)と式(5)より，事後確率を設定したことで y の分布はベルヌーイ分布で表すことができる．

$$f(y|\pi) = \pi^y(1 - \pi)^{1-y} \quad (7)$$

式(7)にロジスティック回帰モデルを代入することで，目的変数と説明変数が結びつき，尤度関数と対数尤度関数を求めることができる．

$$L = \prod_{i=1}^n f(y_i|a_i, \beta_0, \beta) = \prod_{i=1}^n \pi(a_i)^{y_i} \{1 - \pi(a_i)\}^{1-y_i} \quad (8)$$

$$\ell = \log L = \sum_{i=1}^n [y_i \log \pi(a_i) + (1 - y_i) \log \{1 - \pi(a_i)\}] \quad (9)$$

式(9)を最大化することでパラメータ (β_0, β) が求めることができる．

4. 1. 3 サポートベクターマシン

サポートベクターマシン（Support Vector Machine : SVM）は，非線形関数によって高次元特徴空間へ写像し，特徴空間上に構築された超平面に基づき分類を行う手法である[36]． a を高次元特徴空間へ写像する関数を $\phi(a)$ とすると，空間上の超平面は，

$$w^T \phi(a) + b = 0 \quad (10)$$

と定義される．式(10)をもとに，識別関数 $f(a)$ は次のように考えることができる．

$$f(a) = \text{sgn}(w^T \phi(a) + b) \quad (11)$$

式(11)を用いて予測値は、以下ように定義できる.

$$f(a) = \begin{cases} \geq 0, & \text{if } a_i \in c_1 \\ < 0, & \text{if } a_i \in c_2 \end{cases} \quad (12)$$

ここで, パラメータ w と b は以下のような最適化問題を解くことで求めることができる.

$$\begin{aligned} \min_{w, b, \xi} \quad & \frac{1}{2} w^T w + Cost \sum_{i=1}^n \xi_i \\ \text{subject to} \quad & y_i(w^T \phi(a_i) + b) \geq 1 - \xi_i, \quad \xi_i \geq 0, \quad i = 1, \dots, n \end{aligned} \quad (13)$$

ξ_i は, スラック変数と呼ばれ, 他のラベル領域へどの程度入り込んだかを表す量を指す. また, $Cost > 0$ は正則化パラメータを表す. 式(13)より, このような最適化問題は以下の双対問題を解くことで求められる.

$$\begin{aligned} \min_{\alpha} \quad & \frac{1}{2} \alpha^T Q \alpha - e^T \alpha \\ \text{subject to} \quad & y^T \alpha = 0, \quad 0 \leq \alpha_i \leq Cost, \quad i = 1, \dots, n \end{aligned} \quad (14)$$

ここで, e はすべての要素が 1 のベクトルを表し, $Q = y_i y_j \phi(a_i) \phi(a_j) = y_i y_j K(a_j, a_j)$ は, 半正定値行列を示す. この式(14)を解くことで, パラメータ w と b を求めることができる.

4. 1. 4 Naïve Bayes

Naïve Bayes (NB) は、説明変数 A が条件付き独立であると仮定し、ベイズルールに基づいて事後確率が最も高い目的変数に分類する手法である[37].

説明変数 c が与えられた時、説明変数 $A = (A_1, A_2 \dots, A_n)$ の値 $a = (a_1, a_2, \dots, a_n)$ の同時確率 $p(a|c)$ は、条件独立の性質に基づき条件付き確率の積で表すことができる.

$$p(a|c) = \prod_{i=1}^n p(a_i|c) \quad (15)$$

これにより、事後確率 $p(c|a)$ は、

$$p(c|a) = \frac{p(c) \prod_{i=1}^n p(a_i|c)}{p(a)} \quad (16)$$

で求めることができる. Naïve Bayes では、この事後確率 $p(c|a)$ が最も高いクラスを予測値とする. このことより Naïve Bayes の識別関数 $f(a)$ は以下のように表すことができる.

$$f(a) = \arg \max_c p(c|a) \quad (17)$$

主にテキスト分類に強く、電子メールのスパム検出などに用いられる. 図 9 に Naïve Bayes のグラフィカルモデルを示す.




図 9 Naïve Bayes のグラフィカルモデル

4. 1. 5 Tree Augmented Naïve Bayes

Naïve Bayes は，説明変数間の条件付き独立を仮定したが，この条件付き独立を軽減するモデルとして，Tree Augmented Naïve Bayes (TAN) がある[37]. Tree Augmented Naïve Bayes は，特徴量間での条件付き独立を仮定せず，木構造を用いて，特徴量間に依存関係を持たせることができる手法である．図 10 に Tree Augmented Naïve Bayes のグラフィカルモデルを示す．




図 10 Tree Augmented Naïve Bayes のグラフィカルモデル

Naïve Bayes に比べ、表現できる状態数が増加するため、Naïve Bayes より良い分類結果を出すことが期待できる． Tree Augmented Naïve Bayes は、同時確率 $p(a|c)$ を、次のような条件付き確率の積で表す．

$$p(a|c) = \prod_{i=1}^n p(a_i|\Pi_{a_i}) \quad (18)$$

式(20)より、事後確率 $p(c|a)$ は

$$p(c|a) = \frac{p(c) \prod_{i=1}^n p(a_i|\Pi_{a_i})}{p(a)} \quad (19)$$

で求めることができる． 識別関数 $f(a)$ は、式(17)に式(19)を代入することで得られる． Tree Augmented Naïve Bayes の構造学習は、特徴量間での相互情報量を使って行われ、以下の式で表される．

$$I(A_i, A_j|C) = \sum_{A_i, A_j} p(a_i, a_j, c) \log \frac{p(a_i, a_j|c)}{p(a_i|c)p(a_j|c)} \quad (20)$$

式(20)は、説明変数であるノード A_i, A_j 間の条件付き相互情報量であり、この相互情報量をエッジとする最大全域木を求めることで Tree Augmented Naïve Bayes の木構造を決定する．

4. 1. 6 ベイジアンネットワーク

ベイジアンネットワーク (Bayesian network : BN) は, n 個の確率変数集合 $A=\{A_1, A_2, \dots, A_n\}$ の同時確率分布を (G, θ) で表現した確率モデルである[38]. G は, A に対応するノード集合によって構成される非循環有向グラフ(directed acyclic graph : DAG)ネットワーク構造である. θ は, G の各エッジに対応する条件付きパラメータ集合 $\{p(A_i|\Pi_i, G)\}, (i = 1, 2, \dots, N)$ である. ここで, Π_i は変数 A_i の親変数集合を示している. 図 11 にベイジアンネットワークのグラフィカルモデルを示す.




図 11 ベイジアンネットワークのグラフィカルモデル

確率変数集合 $A=\{A_1, A_2, \dots, A_n\}$ を持つベイジアンネットワークの同時確率 $p(A)$ は, 以下のような式で表される.

$$p(A|G) = \prod_i p(A_i|\Pi_i, G) \quad (21)$$

これにより, 事後確率 $p(c|a)$ は

$$p(c|\mathbf{a}) = \frac{p(c) \prod_{j=1}^n p(a_j|\Pi_j, G)}{p(\mathbf{a})} \quad (22)$$

で、求めることができる。また、識別関数 $f(a)$ は、式(17)に式(22)を代入すること
で得られる。ベイジアンネットワークの構造学習は、スコアと呼ばれる指標
を用いて訓練データからネットワーク構造を推定する。スコアを算出するため
には、最小記述長(Minimum Description Length : MDL)などのスコア関数を用
いる[39]。最小記述長は、2つのノード間の方向元を条件とする対数尤度値を計
算し、そのスコアが高い方向に連結する。このスコアベースのネットワーク構
造の探索は、全ノードと全リンク方向に対して行わなければならない、計算量が
指数オーダーであるため NP 完全であることが知られている。近年では、この
問題を解決するために、動的計画法や A*ヒューリスティック探索などの厳密化
探索アルゴリズムが提案されている[40][41]。

4. 2 ニューラルネットワーク

ニューラルネットワークを使用した物体検出は、Regions with CNN
features(R-CNN)や Fast Region-based Convolutional Network (Fast R-CNN)
などの手法があるが、近年提案された You Only Look Once(Yolo)は同等の検出
性能を持ちながら R-CNN の 1000 倍、Fast R-CNN の 100 倍程度、高速に処理
を行うことができると言われている[26][28][42]。

R-CNN などの物体検出の基本的な流れは、以下のとおりである。


1. 画像（教師データ）をもとに、クラス分類モデルを学習する。
2. 与えられた画像の中から、オブジェクトらしい候補領域を多数切り出す[32]。
3. 切り出された多数の候補領域について、1で求めたモデルを用いてオブジ
ェクトの各クラスの確率を推論し、より高確率の候補領域を探す。

この検出手法は、1枚の画像の中の候補領域が数千に及ぶ場合もあり、それぞれの候補領域に対して畳み込みニューラルネットワーク(Convolutional Neural Network : CNN)を用いて推論する場合、多くの時間を要する。

しかし、Yolo は、候補領域の切り出しとその候補領域のクラス確率の算出を 1 度の推論で同時に行う。これにより R-CNN などの従来の手法より非常に高速に物体検出を行うことが可能となる。

4. 2. 1 You Only Look Once

You Only Look Once(Yolo)は, CNN を用いた物体検出手法であり, 24 層の畳み込み層と 2 層の全結合層のニューラルネットワーク構造を持つ[42]. 図 12 にネットワーク構造を示す.



出典：Redmon, Joseph, et al. "You only look once: Unified, real-time object detection." arXiv preprint arXiv:1506.02640 (2015)

図 12 You Only Look Once のニューラルネットワーク構造

Yolo の学習は、448×448 ピクセル固定の入力画像によって行われ、訓練データは、候補領域データとセルデータの2種類のデータから構成されている。この候補領域がセル上のオブジェクトに適合するように、ニューラルネットワークの重みを学習する。損失関数には Intersection Over Union (IOU) を使用する。

る．この IOU は候補領域 b とセル g の重複割合を評価する関数である．以下に IOU 評価関数の式を示す．

$$IOU = \frac{|b \cap g|}{|b \cup g|} \quad (23)$$

Yolo は，入力画像を $S \times S$ のセルに区切り，セルごとにクラス確率とそのセル内に中心を持つ bounding box を最大 2 つまで保持することで物体検出を行う．複数のセルにまたがる物体がある場合、複数のセルがその物体の bounding box を返すことで，それらの情報を統合して物体の正確な位置を求めることができる．bounding box は， x ， y ， w ， h 及び，信頼スコアの 5 つの情報から構成される． x と y は，セルの境界を基準にした bounding box の中心座標を表し， w と h は bounding box の幅と高さを表す．信頼スコアは $\text{Pr}(\text{Object}) * \text{IOU}$ で定義されている．

第5章 超音波センサ

本章では，超音波センサから得られた反射波の特徴量と検出対象・センサ間距離を説明変数とした2クラス分類器の比較実験を行った．2クラス分類器は，決定木(DT)，ロジスティック回帰(LR)，サポートベクターマシン(SVM)，Naïve Bayes(NB)，Tree Augmented Naïve Bayes(TAN)，ベイジアンネットワーク(BN)の6つの手法を採用した．検出対象として，人体の他にガラス瓶，ダンボール，壁のデータを取得し，それぞれの検出精度を評価した．データの取得は，苗村らの手法をもとに提案した人体検出ロボットにより行う．以下にデータの取得方法について説明する．

1. 検出対象・センサ間距離 d の限界取得距離を15~50cmの範囲に設定する．
2. 災害救助ロボットによって，15cmまで接近する．
3. 反射波からの特徴量と検出対象・センサ間距離を取得後1cmさがる．
4. 3を繰り返す
5. 50cmを超えた場合，再度2から繰り返す．

これにより，計2640のデータを取得した．それぞれの内訳は，人体1320，その他各440である．

5. 1 2クラス分類器別精度比較実験

5. 1. 1 実験方法

本実験では，各2クラス分類器の比較評価を行うために評価指数を採用することとした．用いる評価指数は，正解率(ACC)，真陽性率(TPR)，真陰性率(TNR)とし，以下のような式で導き出される．

$$ACC[\%] = \frac{TP + TN}{TP + FP + TN + FN} \quad (24)$$

$$TPR[\%] = \frac{TP}{TP + FN} \quad (25)$$

$$TNR[\%] = \frac{TN}{FP + TN} \quad (26)$$

式(24), 式(25), 式(26)のそれぞれの値は表 6 から算出できる.

表 6 予測値と真値の分割表の例

	真値＝人体	真値＝その他物体
予測値＝人体	True Positive(TP)	False Positive(FP)
予測値＝その他物体	False Negative(FN)	True Negative(TN)

評価指数を算出するにあたり, 5-fold交差検証法を用いる. この手法は, 取得したデータを5ブロックに分割し, 4ブロックを訓練データ, 1ブロックをテストデータとするものである. これを5回繰り返し, それぞれで算出された評価指数の平均値をとる. これにより推定誤差を少なくすることができる.

5. 1. 2 実験結果

表 7 に 2 クラス分類器別の評価指数を示す.

表 7 2 クラス分類器別評価指数[%]

2 クラス分類器	DT	LR	SVM	NB	TAN	BN
<i>ACC</i>	81.47	75.04	86.04	67.07	80.83	80.47
<i>TPR</i>	83.20	80.96	84.41	68.57	81.18	81.41
<i>TNR</i>	80.60	73.39	87.14	68.20	80.20	79.88

表 7 より, 正解率を見ると, 2 クラス分類器別の判別精度は **SVM** が最も高く, **NB** が最も低いことがわかった. **NB** と **LR** の低さの原因は, 変数間が実際には条件付き独立でないためであると考えられる. **TAN** や **BN** では, 取得した説明変数を連続値から離散値に変換するにあたり, その際の情報の損失が精度を下げたと考えられる. そのため, 説明変数が連続で変数間の相関を考慮できる **SVM** が最も精度が高くなったと解釈できる.

第6章 画像センサ

本実験では、画像からの物体検出を行うにあたり検出速度に特化した画像検出・認識用ニューラルネットワークである You Only Look Once(YOLO)を用いて評価実験を行った。実際に画像から情報を取得し学習済みモデルを用意するのは、現実的ではないと判断し、研究開発者元からリリースされている学習済みモデルを用いることとした。検出精度の評価するために、検出精度実験と輝度による検出精度への影響について調査したため以下に示す。

6. 1 検出精度実験

本実験では、画像データから人がいる場所を認識し、人であると検出できているかを調査した。テストデータとして、人が横たわり全身が写っている画像データ (Person) 936 枚と人が写っていない画像データ (Other) 200 枚の計 1136 枚を用いる。

6. 1. 1 実験方法

入力画像の角度によって検出結果に影響があるか調べた結果、図 13 のように同一の画像データであっても検出結果に大きな影響が出ることが確認できた。



図 13 回転画像の判別結果

この結果を踏まえ本実験では、テストデータ 1136 枚それぞれの画像をもとに左右 90 度ずつ回転させた画像データも入力し、いずれかで人であると判別できれば検出できたとする。しかし、Other データに対して人であるという検出を行った場合、これを誤検出とする。

6. 1. 2 実験結果

検出結果から、式(24)、式(25)、式(26)を用いて評価指数を算出した結果、正解率 97.18%、真陽性率 100.00%、真陰性率 84.00%となった。このことより、Person データ 936 枚全てにおいて人であると検出できたといえる。しかし、Other データでも人が検出できたとする誤検出が複数回確認できた。誤検出の場合、検出結果の期待値が 20%から 32%になることが確認されている。そのため、期待値が 32%を下回るものは、超音波センサを用いた再検出を行うこととした。

6. 2 輝度による判別精度への影響

災害現場において画像センサは有効であることが先の実験でも証明できた。しかし、画像センサは暗所では有用な情報を取得できないという短所も存在する。本実験では、Person データ 936 枚の元画像の輝度を調節することで擬似的な暗所画像を作成し、輝度による判別精度への影響について調査した。図 14 にその輝度調整のイメージを示す。



図 14 輝度調整のイメージ

6. 2. 1 実験方法

1 つの画像データから輝度を 100%, 50%, 25%, 10%, 8%, 5% に調整した複数の画像データを作成し、それぞれの画像データから人体が検出できるか調査した。判別精度に著しい低下がみられた場合、その輝度を数値化し、判別精度に影響を及ぼす輝度値の目安として定める。これにより、人体検出ロボットが暗所で人体を検出する時、画像センサによる探索が可能であるかどうか判断できる。輝度の数値化は、画像を NTSC 加重平均法によるグレースケールに変換し、ピクセルごとの輝度値を更新後、全体の輝度値の平均を算出することで数値化を行う。以下に NTSC 加重平均法によるグレースケール変換式を示す。

$$Y = (0.298912 * R + 0.586611 * G + 0.114478 * B) \quad (27)$$

対象とするテストデータは、Person データから無作為に選出した 200 枚の画像データとする。

6. 2. 2 実験結果

輝度別の検出率を表 8 に示す. 検出結果は, 式(24)を用いて正解率で算出した.

表 8 輝度による検出精度への影響

輝度	100%	50%	25%	10%	8%	5%
ACC[%]	100.00	100.00	98.40	91.03	57.48	0

表 8 から, 画像データによる検出精度は輝度が元画像の 10%を下回ると著しく低下することがわかる. この実験結果をもとに, 今回使用したテストデータ 200 枚の中から無作為に 30 枚の画像を選出し, 各画像の輝度が 10%の時のグレースケール変換を行った. それにより平均輝度値が約 15 以下であると検出精度に大きな影響があることが明確になった. そのため, 暗所での画像センサによる人体検出は, 取得した画像をグレースケール変換し, 平均輝度値が 15 以下の場合, 画像センサによる人体検出を行わないものとした.

第7章 実証実験

これまでの結果をもとに、画像センサと超音波センサを搭載した人体検出口ボットを開発し、動作確認を行った。図 15 に動作確認時の実験環境を示す。実験環境は、災害現場を想定し、瓦礫などの代わりにダンボールやガラス瓶を障害物として設置した。




図 15 動作確認の実験環境

開発したロボットの人体検出までの流れは、図 1 で示すように、画像センサと超音波センサから同時に情報を取得し、それぞれ異なった機械学習手法を用いて人体を検出するものである。この時、超音波センサから得た情報を分類する 2 クラス分類器には、人体検出精度が最も高かった SVM を採用した。動作確認の結果、開発したロボットは、提案した人体検出手法に基づいて人体を検出することが確認できた。

本章では、画像センサと超音波センサを搭載した人体検出ロボットの有用性を示すため、苗村らの研究で問題であった、人体の検出可能距離の制限と検出不可能箇所が存在について改善されているか検証したため以下に示す。

7. 1 人体検出可能距離の測定実験

7. 1. 1 実験方法

本実験では、検出対象(頭部)とロボットを直線上に配置し、距離別の人体検出精度を比較した。この時、提案手法がいかに改善できているか比較するため各センサ単体による人体検出も行った。本研究では、災害現場の屋内を探索することを想定しているため最長限度を3mと設定し、人体検出距離の測定の範囲は、15cmから3mとした。検出距離点は15cm, 30cm, 45cm, 1m, 2m, 3mの6点で、各点30回ずつ検出実験を行った。実験環境を図16に示す。




図 16 人体検出可能距離の測定実験

検出距離が50cm以下の場合、超音波センサにより、正確な距離を求めることが可能であった。しかし、それ以上の距離の場合、対象物の材質などの影響を

受け距離の測定精度が大きく低下した．そのため1m, 2m, 3mの3点は，手動で測定し，その地点に人体検出口ボットを置くことで人体検出を試みた．

7. 1. 2 実験結果

検出距離別に超音波センサと画像センサを用いて人体検出を行った．その結果を正解率として表 9 に示す．

表 9 人体検出可能距離の測定結果[%]

検出距離	15cm	30cm	45cm	1m	2m	3m
超音波	70.00	73.33	40.00	0.00	0.00	0.00
画像	0.00	30.00	100.00	100.00	100.00	100.00
提案手法	66.67	76.67	100.00	100.00	100.00	100.00

検出は，提案手法に基づき，超音波センサと画像センサ両方で同時に使って行った．検出箇所は，苗村らと条件を同じにするため頭部に限定した．その結果，45cm 以上では，画像センサにより人体を 100%検出できた．しかし，30cm 未満では，画像センサが近すぎてうまく検出することができなかった．そのため，30cm 未満の検出は，超音波センサ単体での検出結果となった．

7. 2 人体部位別検出精度実験

7. 2. 1 実験方法

本実験では，人体の部位別検出精度について検証を行った．測定箇所は頭部，上半身，下半身，手の 4 箇所を対象とし，それぞれの検出箇所以外をダンボールや壁などの障害物により隠すことで調査した．実験方法は先の実験と同様に対象箇所と人体検出口ボットを直線上に配置し，今回は 15cm , 45cm, 1m の 3

点で人体検出を行うこととした。3 点の距離でそれぞれ 30 回ずつ検出を行ない、検出精度を算出する。図 17 に人体部位別検出成功例を示す。




図 17 人体部位別検出成功例

検出距離が 1m の点は、手動で測定し、その地点に人体検出口ボットを置くことで人体検出を試みた。

7. 2. 2 実験結果

提案手法を用いた人体の部位別検出精度実験の結果を以下の表に示す。

表 10 頭部の検出精度比較[%]

検出距離	15cm	45cm	1m
超音波	70.00	40.0	0.00
画像	0.00	100.00	100.00
提案手法	70.00	100.00	100.00

表 11 上半身の検出精度比較[%]

検出距離	15cm	45cm	1m
超音波	0.00	0.00	0.00
画像	0.00	43.33	90.00
提案手法	0.00	43.33	90.00

表 12 下半身の検出精度比較[%]

検出距離	15cm	45cm	1m
超音波	0.00	0.00	0.00
画像	0.00	20.00	70.00
提案手法	0.00	2.00	70.00

表 13 手の検出精度比較[%]

検出距離	15cm	45cm	1m
超音波	56.67	26.67	0.00
画像	40.00	86.67	13.33
提案手法	66.67	96.67	10.00

実験結果より，人体の部位別検出精度は頭部や手など肌が露出している部分の検出精度が高いことがわかる．これは，肌が露出していたため超音波センサにより検出可能であったことが大きな要因の1つとしてあげられる．超音波センサ単体による検出精度はそこまで高いものとは言い難く検出精度が100%になることはない．しかし，超音波センサで検出できなかった対象部位も画像センサによって補うことで検出精度の向上していることがわかる．

第8章 結言

本研究では、超音波センサと画像センサを用いた新たな人体検出手法を提案し、これを実装した人体検出口ボットの開発した。提案する検出手法は、超音波センサと画像センサから同時に情報を取得し、それぞれ異なった機械学習手法を用いて人体の検出を行うものである。超音波センサからの人体検出手法は、苗村らの人体検出手法をベースに検出対象・センサ間距離と超音波の反射波から特徴量を抽出し、それぞれを説明変数とした2クラス分類器によって人体の検出を行う。検出対象・センサ間距離と超音波の反射波から抽出した特徴量をもとに2クラス分類器別の精度比較実験を行った結果、SVMが最も高い検出精度を誇ることが確認できた。画像センサからの人体検出手法は、機械学習手法の1つであるニューラルネットワークを活用し人体検出を行う。画像センサから取得した画像データをもとにその性能を評価する実験を行った結果、人体全体が写っていない画像データであっても高い検出精度を誇ることがわかった。しかし、人体やその他物体の映り方によって誤検出も存在した。誤検出の場合、総じて検出結果の期待値が低くなるため、画像センサから人体を検出し、期待値が低い場合に限り超音波センサを用いた2段階検出を行うこととした。これにより検出精度は一段と向上する。画像センサの輝度による検出精度への影響実験では、画像をグレースケール変換し、平均輝度値が約15以下になると検出精度への影響が大きくなることが確認できた。影響を及ぼす輝度値が明確になったことにより、2段階認証を行う機会が減り、人体検出を行う時間の短縮につながったと言える。この人体検出口ボットは、超音波センサと画像センサを搭載することにより、超音波センサ1つでは成しえなかった高い汎用性を示し、災害現場などの厳しい状況下でも周囲の環境に依存しない優れたセンシング能力を有

することが確認できた。今後は、超音波センサと画像センサ以外のセンサを搭載し、より汎用性の高いロボットを目指す。それにより、災害現場だけでなく、様々な現場や環境への応用が期待出来る。

謝辞

本研究を進めるにあたり，研究の方向性や統計学・機械学習手法についてご指導を賜り常に適切なご助言をいただきました主任指導教員の植野真臣教授に心から御礼申し上げます．また，指導教員の川野秀一准教授，並びに西山悠助教，宇都雅輝助教には，研究に関して常に多方面からのご助言いただきましたこと深く感謝いたします。そして，NTT アドバンステクノロジー株式会社の苗村智行氏には，電気回路制作や動作アルゴリズム，機械学習手法について多大なるご助言とサポートをして頂きましたことに感謝いたします

最後に，日頃の会話を通じて多くの知識や示唆を頂いた植野・川野研究室の皆様感謝します。

参考文献

- [1] 国土交通省近畿地方整備局：“阪神・淡路大震災の経験に学ぶ”，
<http://www.kkr.mlit.go.jp/plan/daishinsai/> (参照 2017/07/25)
- [2] 松野俊文, 大塚寛：“レスキューロボットシステムの研究開発の現状”，IEEEJ
Journal, vol.125, No.9, pp.570-573, 2005
- [3] 高森年：“レスキュー活動へのロボット技術導入の期待”，日本ロボット学会
誌 17(5), pp.620-626, 1999
- [4] 浅間一：“災害・事故対応に求められるロボット技術”，まてりあ, vol.51, No.4,
2012
- [5] 田所諭：“レスキューロボットの現状と未来”，電子情報通信学会 92(3),
203-208, 2009
- [6] 徳田献一：“レスキューロボットに見る災害対応の取り組み”，和歌山大学防
災研究教育センター紀要, Vol.1,2015
- [7] 田所諭：“災害対応ロボットのあるべき姿”，建設の施工企画 (753),
pp.23~31, 2012
- [8] 樽木久征, 大野英, 小野文枝, 浜本隆之, 佐々木朋詩, 白井稔人, 坂井正
善：“環境光の影響を抑制した物体検出用イメージセンサ”，映像メディア学
会誌, Vol.61, No.12, pp.1810-1817, 2007
- [9] A Fod, A Howard, M Mataric: “Laser-Based People Tracking”, IEEE
International Conference on Robotics and Automation(ICRA),
pp.3024-3029, 2002
- [10] A Himoto, H Aoyama, O Fuchiwaki : “Development of Micro Rescue
Robot - Human Detection”, IEEE International Conference on
Mechatronics, pp.526~531, 2005
- [11] P Hauptmann, N Hoppe, A Puttmer: “Application of ultrasonic sensors in
the process industry”, Measurement Science and Technology, Vol.13, No.8,
2002
- [12] S Bhatia, H S Dhillon, Nitin Kumar: ”Alive Human Body Detection
system using an Autonomous Mobile Rescue Robot”, Annual IEEE India
Conference, 2011
- [13] Sonia, A M Tripathi, R D Baruah S B Nair: “Ultrasonic Sensor-based
Human Detector using One-class Classifiers”, IEEE International

- Conference on Evolving and Adaptive Intelligent Systems, 2015
- [14] 苗村智行, 山本健司, 西山悠, 植野真臣: “超音波による人体検出機能を持つ移動ロボットの開発”, The Institute of Electrical Engineers of Japan, Vol.3, pp.121-122, 2017
 - [15] M Barnard: “Tesla & Google Disagree About LIDAR — Which Is Right?”, <https://cleantechnica.com/2016/07/29/tesla-google-disagree-lidar-right/>, (参照 2017/07/25)
 - [16] A Mohan, C Papageorgiou, T Poggio: “Example-based object detection in images by components”, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol.23, No.4, pp.349–361, 2001
 - [17] P Viola, M Jones, D Snow: “Detecting Pedestrians Using Patterns of Motion and Appearance”, IEEE International Conference on Computer Vision (ICCV), pp.734-741, 2003
 - [18] T Tanaka, H Haruyama: “New Position Detection Method Using Image Sensor and Visible Light LEDs” , 2009 Second International Conference on Machine Vision, pp.150-153, 2009
 - [19] Y Yagi, S Kawato, S Tsuji: “Real-time omnidirectional image sensor (COPIS) for vision-guided navigation”, IEEE Transactions on Robotics and Automation, Vol.10, pp.11-22, 1994
 - [20] T Ogawa, H Sakai, Y Suzuki, K Takagi, K Morikawa: “Pedestrian Detection and Tracking using in-vehicle Lidar for Automotive Application”, Intelligent Vehicles Symposium, 2011
 - [21] K Natsume, Y Miyake, K Hoshino, C Yamano: “Compact High-resolution Millimeter-wave Radar for Front-obstacle Detection”, Conference: SAE 2006 World Congress & Exhibition, 2006
 - [22] J Borenstein, Y Koren: “Obstacle avoidance with ultrasonic sensors”, IEEE Journal on Robotics and Automation, Vol.4, pp.213-218, 1988
 - [23] P Zhang, B Huang, T Baba, "Obstacle detecting system for vehicle collision safeguard", International Conference on Communications. Circuits and Systems 2007, pp. 1317-1321, 2007.
 - [24] K Song, C Chen, C Huang: “Design and experimental study of an ultrasonic sensor system for lateral collision avoidance at low speeds”, IEEE Intelligent Vehicles Symposium, 2004

- [25] J R Llata, E G Sarabia, J P Oria: "Fuzzy expert system with double knowledge base for ultrasonic classification", *Expert Systems with Applications* 20, pp.347-355, 2001
- [26] R Girshick, J Donahue, T Darrell, J Malik: "Rich feature hierarchies for accurate object detection and semantic segmentation.", *CVPR '14 Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition*, pp. 580-587, 2014.
- [27] K He, X Zhang, S Ren, J Sun: "Spatial pyramid pooling in deep convolutional networks for visual recognition.", *European Conference on Computer Vision*, pp.346-361, 2014
- [28] R Girshick: "Fast r-cnn." *Proceedings of the IEEE International Conference on Computer Vision*. 2015.
- [29] S Ren, K He, R Girshick: "Faster R-CNN: Towards real-time object detection with region proposal networks.", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.39, pp.1137-1149, 2017
- [30] W Liu, D Anguelov, D Erhan, C Szegedy, S Reed, C Fu, A C Berg: "SSD: Single Shot MultiBox Detector.", *ECCV 2016 Computer Vision and Pattern Recognition*, 2015
- [31] J R R Uijlings, K E A van de Sande, T Gevers, A W M Smeulders: "Selective search for object recognition." *International journal of computer vision*, pp.154-171, 2013
- [32] A Krizhevsky, I Sutskever, G E Hinton: "Imagenet classification with deep convolutional neural networks.", *NIPS'12 Proceedings of the 25th International Conference on Neural Information Processing Systems*, Vol.1, pp.1097-1105, 2012
- [33] Menzies, Y Hu: "Data Mining for Very Busy People", *Computer* 36, pp.22-29, 2003
- [34] X Wu, V Kumar, R Quinlan, Q Yang, H Motoda, G J McLachlan, A Ng, B Liu, P S Yu, Z Zhou, M Steinbach, D J Hand, D Steinberg: "Top 10 algorithms in data mining", *Knowledge and Information Systems*, Vol.14, pp.1-37, 2008
- [35] J Peng, K Lee, G Ingersoll: "An Introduction to Logistic Regression Analysis and Reporting", *The Journal of Educational Research* 96(1),

- pp.3-14, 2002
- [36] C Cortes, V Vapnik: "Support vector networks", Machine Learning 20, pp.273-297, 1995
 - [37] N Friedman, D Geiger, M Goldszmidt: "Bayesian network classifiers", Machine Learning 29, pp.131-163,1997
 - [38] 植野真臣 : “ベイジアンネットワーク” , コロナ社, 2013
 - [39] M. Delampady: "Minimum Description Length Methods in Bayesian Model Selection: Some Applications", Open Journal of Statistics, Vol. 3 No. 2, pp. 103-117, 2013
 - [40] T Silander, P Myllymäki: “A Simple Approach for Finding the Globally Optimal Bayesian Network Structure”, Twenty-second Annual Conference on Uncertainty in Artificial Intelligence, pp.445-452, 2006
 - [41] C Yuan, B Malone, X Wu: “Learning Optimal Bayesian Networks Using A* Search”, Proceedings of the 22nd International Joint Conference on Artificial Intelligence, pp.2186-2191, 2011
 - [42] J Redmon, S Divvala, R Girshick: "You only look once: Unified, real-time object detection.", IEEE Conference on Computer Vision and Pattern Recognition, 2016