

機械学習を用いた医療機器の視覚アラーム検出に関する検討

Fundamental study of visual alarm detection method for medical equipment using machine learning

渡邊 翔太郎*

Shotaro Watanabe*

Abstract

When a medical equipment detects any abnormality during treatment, it notifies a clinical engineer or other medical staff of the abnormality by an alarm sound. Alarm sound is stressful to the patient because it sounds loud and frequent. To solve this problem, we developed a novel silent alarm system for medical equipment using image recognition technology. This method detected a visual alarm by color extraction processing, but there was also a false detection. In this study, we used machine learning to improve the detection rate of visual alarms in medical equipment. The target of the learning model was a dialysis machine. The number of captured images was 60 each when an alarm occurred and when there was non-alarm, for a total of 120 images. These images were annotated, and a learning model was created including the correct label and its position information. The learning model used YOLOv5. As a learning result, precision and recall, mAP (mean Average Precision) were 0.998 and 1.000, 0.995 that we were able to create a learning model with a high detection rate. Furthermore, the detection results of the image data for test were 0.90 to 0.94, which was a very high detection rate. This alert system may be a useful alternative to patient reduce the stress on caused by the alarm sounds.

1. はじめに

医療機器は、治療中における何らかの異常を検知すると、その異常をアラーム信号によって、臨床工学技士や他の医療従事者に知らせている。医療機器のアラーム信号は、「JIS T 6060-1-1-8」に規定されており、点灯装置や液晶モニタなどから視覚アラーム信号を発生させなければならないとしている⁽¹⁾。さらに、状況に応じて音響や音声、振動などの追加のアラーム信号を設けることを勧めている。臨床現場では、この追加のアラーム信号として音響信号であるアラーム音を併用することが多く、特に治療中の異常を伝えるという重要な役割を担っていることから、その音量を大きくすることを推奨している⁽²⁾。しかし、アラーム音は大きく頻りに鳴るため、患者のストレスになっていることが問題となっている⁽³⁾。警報装置に関するユーザアンケート

調査では、「患者からアラーム音についてどのようなクレームを受けましたか？」という問いに、「音がうるさい」や「アラームを聞くと不安になる」といった回答が寄せられている⁽⁴⁾。また、人工透析療法に用いられる透析用監視装置の警報音は62dBと、患者・スタッフの会話時の64dBに次いで大きいことを報告している⁽⁵⁾。集中治療室(ICU)では、アラームが多すぎることや聴覚警告は患者の回復に、障害を与えている可能性を指摘している⁽⁶⁾。このように医療機器から発せられるアラーム音は、騒音や障害の原因となっており、病棟やICU、その他の臨床現場の環境を整えるという面では、その音量を小さくすることが望まれる。

一方で、野口らは医療機器付属のRS-232Cインターフェースから警報情報の取得を行い、アラーム情報の集中管理を行う方法を報告している⁽⁷⁾。通信

*北海道科学大学保健医療学部臨床工学科

インターフェースを利用することで、音響信号を必要とせず医療従事者に直接通知することが可能である。しかし、医療機器の機種ごとにより通信プロトコルが異なるため、それぞれにプログラムを開発する必要がある。そのため、機種別の限定的なアラームシステムになるといった課題が挙げられる。

そこで、我々はアラーム音を原因とする臨床現場の環境改善を目的に、治療中の異常を伝える医療機器の新たな静音アラームシステムの開発を行ってきた⁽⁸⁾。これは、医療機器から発せられる汎用的な視覚アラームに着目したシステムであり、その視覚アラームを Web カメラで捉え、画像認識技術の一つである色抽出処理を用いてアラームを検出し、ネットワークを介して、その情報を医療従事者の持つ携帯情報端末に通知するものである。これにより、視覚アラームの発生を 90%以上の一致率で検出でき、静音アラームシステムとして有用であったことを確認した。しかし、従来の色抽出処理では、危険警告や緊急対処が必要となるときに表示される、点灯装置の赤色のみに着目したものであったため、Web カメラに映り込む同様の赤色を誤検出することがわかった。つまり、一定の確率で誤警報の発生が示唆された。

そこで、本研究は医療機器の視覚アラーム検出において、新たに産業分野や自動運転技術、近年では、健康管理や医療技術に関連するアプリケーション等で、急速に発展している機械学習を活用した^(9, 10, 11)。機械学習を利用した画像認識により、点灯装置そのものの特徴量を学習させ、従来法で誤検出となっていた視覚アラームの検出率向上を検討した。

2. 方法

2-1. 医療機器の視覚アラーム

医療機器の中の例えば透析用監視装置には、視覚アラームを知らせるために、図 1 に示すようなパイロットランプ（点灯装置）が備えつけられている。通常、パイロットランプは操作準備完了の緑色であり、警告・注意の際には黄色、危険警告や緊急に対処が必要となる時には赤色となる。このように、治療中の異常を検知した際は、パイロットランプでアラームの発生とその重要度を視認できるようになっている。

本研究では、パイロットランプが点灯していない場合を非アラーム時、パイロットランプが赤色に点

灯している場合をアラーム発生時とし、アラームを検出した。

2-2. 機械学習を利用した検出方法

機械学習は、事前に与えた大量の教師データにより、そのデータが持つ特徴を学習し、その特徴を利用して自動的に新たなデータを判定する技術である。この機械学習による画像認識の方法は、そのタスクによって画像分類、物体検出、領域分類に大きく分けられる。画像分類は、一つの画像に写っている物体が何であるかを一つの答えとして提示するものであり、そこに物体の位置は示されない。本研究では対象となる物体の境界（パイロットランプとそれ以外の風景や対象物の境界）を認識するため、物体検出によりアラーム検出を行うこととした。物体検出は、図 2 に示すように画像内に写っている物体がそれぞれ何であるかを特定し、さらにその位置情報を、物体を取り囲む矩形（バウンディングボックス）で提示する⁽¹²⁾。この例では、画像に写った犬と猫を認識している。



図 1 透析用監視装置のアラーム発生時の例

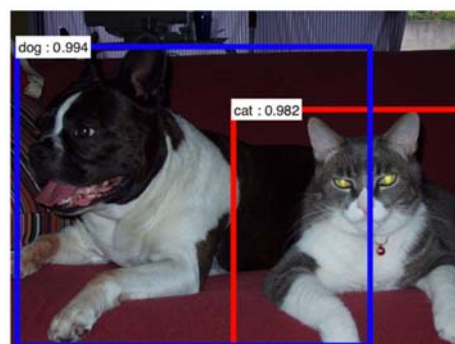


図 2 物体検出の例

このような、物体検出の方法は様々な手法があり、中でも CNN (Convolutional Neural Network: 畳み込みニューラルネットワーク) が有効な仕組みで、顔検出等にも応用されている。特に、CNN を利用した物体検出の分野では、R-CNN (Region with CNN) や SSD (Single Shot MultiBox Detector) などの手法が開発され、幅広く応用されている^(13, 14)。その中で本研究では、2016年に Joseph Redomらによって発表された YOLO (You Only Look Once) を用いることとした⁽¹⁵⁾。YOLO は、リアルタイム性に優れた物体検出アルゴリズムであり、入力画像を 1 回 CNN に通すことでオブジェクトを検出することができる。YOLO は、これまでに v1 から v5 までのバージョンが公表されており、特に YOLOv5 は 2020 年に公開された最新のモデルである。YOLOv5 のリアルタイム性は、他の手法に比べて 100 ~ 1,000 倍以上の超高速処理を実現している⁽¹⁶⁾。また、検出精度と演算負荷に応じて 4 つのタイプを選択できるようになっており、このうち最も負荷の小さいモデルであっても精度良く検出できる。そのため、使用するハードウェアやデータ数に応じた設定ができ、現場での適用も汎用的に可能であると考えられる。

以上のことから、本研究におけるアラーム検出ではリアルタイムかつ高速で物体検出が可能な YOLOv5 が有用であると考えた。

2-3. 学習モデルの構築

機械学習では、正解ラベルを含む画像データを学習させ、学習モデルを作成する必要がある。今回、学習モデルの対象とした医療機器は、北海道科学大学の実習室内に設置されている透析用監視装置とした。撮影画像は図 3 に示すように透析用監視装置のパイロットランプが映り込むことように、ランダムな角度と距離から、アラーム発生時と非アラーム時をそれぞれ 60 枚撮影し、計 120 枚とした。撮影機材はスマートフォン (iPhone 12 Pro, Apple Inc. 解像度: 3,200 × 3,200) を使用した。撮影画像に正解ラベルを付与するため、VoTT (Visual Object Tagging Tool, Microsoft) を使用し、アノテーションを行った⁽¹⁷⁾。アノテーションとは、特定のデータにラベル (注釈) を付加することである。本研究では図 4 に示すようにアラーム発生時と非アラーム時のパイロットランプをそれぞれ赤と緑の矩形で囲み、それぞれに “alarm”, ” non-alarm” とラベル付けを行った。これらのデータは JSON

(JavaScript Object Notation) フォーマットでエクスポートし、jpeg 画像と正解ラベル (テキスト)、位置情報 (座標) を YOLO に取り込み、機械学習を行った。取り込んだデータは表 1 に示すように、それぞれにおいて学習データを 96 枚 (120 枚の 8 割)、訓練データを 24 枚 (120 枚の 2 割) に分けてデータセットとした。なお、今回の実験では、画像データ




図 3 撮影画像データの 6 例

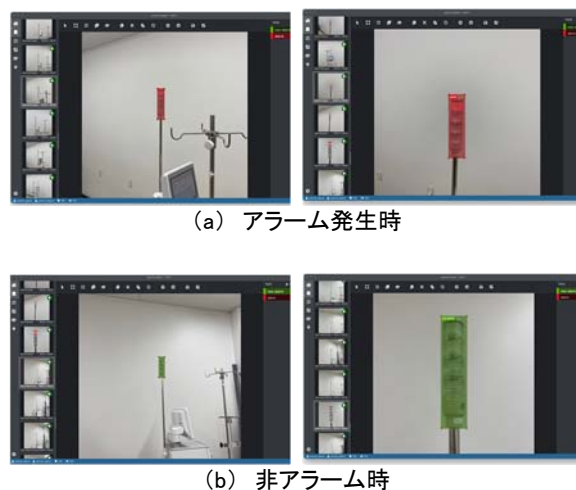


図 4 VoTT を使用したアノテーションの 4 例

表 1 データセット

	学習データ	訓練データ
アラーム発生時	48 枚	12 枚
非アラーム時	48 枚	12 枚

のコントラストの変更や画像の回転など、いわゆる水増し処理は行なわないこととした。また、YOLOには、動物や乗り物、コップなどの身の回りの物を学習した既存の学習モデルがある。これを再利用するいわゆる転移学習を行うことで、高精度な学習が可能となる他、学習にかかる時間を削減することができる。しかし、本研究では、これらのデータに関連性がないことやアラームの検出のみを対象としているため、転移学習は行わないこととした。

機械学習における各パラメータは、学習回数を500回とし、バッチサイズは32、最適化手法にはSGD（確率的勾配降下法: Stochastic Gradient Descent）を採用した。なお、YOLOを実行する際のオプション（パラメータ）は、全てデフォルト値とした。構築環境は表2に示す通りで、学習モデルの作成には約14時間を要した。

表2 構築環境

コンピュータ	Mac mini M1 2020
OS	macOS Monterey 12.0.1
チップ	Apple M1
メモリ	8 GB
プログラミング言語	Python 3.8.10

2-4. 学習モデルの評価方法

学習モデルの評価指標は、物体検出でよく用いられる適合率（検出した対象物が正しい比率）、再現率（検出すべき対象物を検出できない比率）、mAP（mean Average Precision）を用いた。mAPは、正解ラベルに対して、どれくらいバウンディングボックスが重なっていれば検出成功とみなすかという指標であり、50%の重なりがあれば、正解とみなされる。適合率、再現率およびmAPの算出式を下記に示す。それぞれ、TP（True Positive）は真陽性、FP（False Positive）は偽陽性、FN（False Negative）は偽陰性を表す。mAPの計算は、平均適合率（AP: Average Precision）を正解ラベルの数（C）でさらに平均したものである⁽¹⁸⁾。

また、学習データと訓練データに使用していない検証用画像20枚（アラーム発生時と非アラーム時の画像それぞれ10枚ずつ）を用いて、検出判定を

行った。これらの画像には、従来法で誤検出したパイロットランプの赤色と同様の物体が写り込んだ画像も含まれている。

$$\text{適合率} = \frac{TP}{TP+FP} \quad (1)$$

$$\text{再現率} = \frac{TP}{TP+FN} \quad (2)$$

$$\text{mAP} = \frac{1}{C} \sum_{i=1}^C AP_i \quad (3)$$

3. 結果

前章において作成した学習モデルの適合率と再現率の結果をそれぞれ図5に示す。ともに、学習回数が増えていくにつれて、再現率および適合率が1.0（100.0%）に近づいていき、学習回数450回付近で、変化が小さくなり安定した。最終的には（学習回数500回目では）、再現率が0.998（99.8%）、適合率が1.000（100.0%）であった。このことから、学習回数に不足はなく、適合率および再現率の高い学習モデルを作成することができた。次に、mAPの結果を図6に示す。これについても学習回数450回

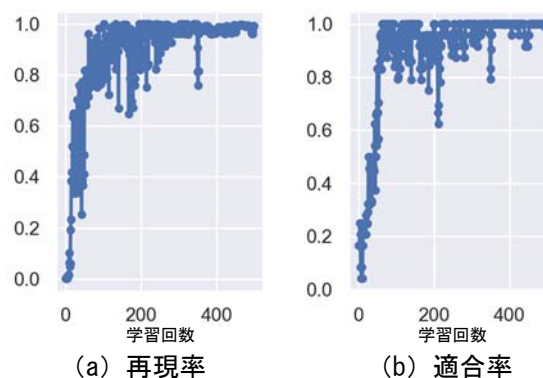


図5 学習モデルの評価結果




図6 mAPの結果

付近で変化が小さくなっていき安定した。最終的には(学習回数 500 回目では), mAP が 0.995 (99.5%) であった。このことから, 正解ラベルに対してバウンディングボックスの重なりが 50%以上で適合していることがわかった。

次に検証用画像のアラーム発生時および非アラーム時の検出判定結果を図 7 と図 8 に示す。図 7 と図 8 では, 検出された箇所をバウンディングボックスで囲い, その上に, 検出結果の信頼度を示している。この信頼度は, バウンディングボックス内にアラーム発生時および非アラーム時のラベルが含まれているかの確率を示す⁽¹⁵⁾。ともに 0.90 (90%) から 0.94 (94%) と非常に高い値で検出され, パイロットランプの大きさや角度に影響なく検出された。特に, 図 7 (b) や図 8 (b) は, 従来法で用いたような他の同様の赤色が含まれている画像であるが, アラーム発生時と非アラーム時を高い信頼度で検出できた。また, 非アラーム時の透析用監視装置のパイロットランプはほぼ無色透明であったが, 実習室の白壁との境界を捉えることができた。

表 3 にそれぞれ 10 枚の正解率と信頼度の平均値 (±SD) を示す。判定画像全てにおいて正解率は 100%であり, 誤検出はなく, 信頼度もそれぞれ高い結果となった。

表 3 検証用画像の検出結果

	判定画像 (枚)	正解率 (%)	信頼度 (平均±SD)
アラーム発生時	10	100	0.93± 0.019
非アラーム時	10	100	0.92± 0.028

4. 考察

本研究は, アラーム検出において機械学習を活用し, その検出率について検討を行った。適合率, 再現率および mAP とともに学習回数を重ねることで, 1.000 (100%) 付近で収束し, 良い検出モデルを作成できたと考える。今回, 学習モデルの対象とした医療機器は透析用監視装置のパイロットランプで, 距離によってその大きさは変わるが, 捉える角度によって見え方の変化はなく, 画一的な対象物であっ





図 7 アラーム発生時を検出した結果




図 8 非アラーム時を検出した結果

た。そのため、良い学習モデルを作成できたと考えられる。また、検証用画像を判定した結果、精度よく検出でき、かつ、従来の方法で問題となっていた同色の赤色を含む画像においても、正しくパイロットランプを検出し、誤検出もなかった。特に透析用監視装置は、アラームの赤色と同色のダイアライザという特有の医療材料が用いられる。今回の結果からも従来の色抽出処理よりも良い結果となったことがわかる。しかし、医療機器には様々な付属機器があり、また、臨床現場には対象とする医療機器とは関係のない物もいくつか散在する。今回作成した学習モデルでは、透析用監視装置のパイロットランプのみの学習であるため、その他の物体が存在すると、今回の実験では見られない誤検出が考えられる。さらに、今回の学習はデータセットの水増し処理を行っていないため、コントラストなどの色調変化に対応していない。今後は、画像の水増し処理や今回学習させなかったその他の付属機器等についても学習することで、誤検出の改善が見込めると考えられる。本研究で対象とした透析用監視装置は、透析室にて複数の患者が治療を行う。また、ICUやその他の病室においても、現代医療において複数台の医療機器が用いられる。今回の実験では1台の装置を対象としたが、これらのことを考えると複数台のアラーム検出が有効であることも検証が必要と考える。

また、近年は無線LANを搭載した医療機器も販売されるようになってきている。院内のネットワークを利用することで、医療機器のアラーム情報だけでなく、様々な情報を取得することができる⁽¹⁹⁾。このようなシステムを導入する事により、アラームのない静音な環境構築も行えるが、イニシャルコストが問題となる。医療機器の買い替えも、耐用年数を過ぎるまでは積極的に行えないものである。本システムは所有の医療機器の視覚アラームを学習させ、学習モデルを作成することで実現可能であると考えられる。今後は、在宅でも使用されるような輸液ポンプなどの小型医療機器のアラーム発生状況を取得できるよう、様々な医療機器に機械学習を活用していきたいと考える。

5. 結論

本研究は、従来法の色抽出処理によるアラーム検出において問題であった同色の誤検出を、機械学習を用いることで改善し、検出率を向上することがで

きた。特に、YOLOv5を用いる事により、高い検出率でアラームを認識することができた。本システムはアラーム音によって引き起こされる患者のストレスを軽減するための、代替の静音アラームシステムの一助として有用であると考えられる。

参考文献

- (1) 日本工業標準調査会：JIS T 60601-1-8 医用電気機器-第 1-8 部、基礎安全及び基本性能に関する一般要求事項-副通則、医用電気及び医用電気システムに関する一般要求事項、試験方法及び適用指針、2012。
- (2) 山家敏彦：アラームの仕組み、透析ケア、Vol.17, No.3, pp.222-225, 2011。
- (3) Kopple JD, Shapiro BB, Feroze U, Kim JC, Zhang M, Li Y, Martin DJ: Hemodialysis treatment engenders anxiety and emotional distress, Clin Nephrol, Vol. 88, No. 10, pp. 205-217, 2017。
- (4) 加納隆：警報装置に関するユーザアンケート調査、医器学, Vol.72, No.9, pp.439-442, 2002。
- (5) 日浦由香, 岡田美千子, 後藤知宏, 柏木英里子, 榎学, 浜尾巧: 透析室の騒音測定, 日本透析医学会, Vol.41, pp.792, 2008。
- (6) C. Meredith, J. Edworthy: Are there too many alarms in the intensive care unit? An overview of the problems, Journal of advanced nursing, Vol. 21, No.1, pp. 15-20 January 1995。
- (7) 野口亨, 定松慎矢, 佐々野浩一, 横山武志: 無線ネットワークを利用した機器動作状況管理システムに関する研究, 手術医学, Vol. 37, No. 1, pp.15-20, 2016。
- (8) 渡邊翔太郎, 古谷大輔, 清水久恵: 色抽出処理を用いた透析用監視装置の新しい静音アラームシステムの開発, 北海道科学大学紀要, No. 48, 2020。
- (9) Beaulieu-Jones B, Finlayson SG, Chivers C, Chen I, McDermott M, Kandola J, Dalca AV, Beam A, Fiterau M, Naumann T: Trends and Focus of Machine Learning Applications for Health Research, JAMA Netw Open, Vol.2, No.10, p.e1914051, 2019。
- (10) 松田明大, 松井智一, 松田裕貴, 諏訪博彦, 安本慶一: ドライブレコーダ動画を用いた路上駐

- 停車判定手法の提案, 情報処理学会, Vol. 2020, pp. 1102-1110, 2020.
- (11) 田沼隆夫, 小林達明, 高屋英知, 鈴木大吾, 井上美香, 吉川達生, 小林泰之: 手術用ガーゼ遺残防止支援を目的とした術後 X 線撮影による物体検出深層学習モデル開発のためのファントム実験, 日本放射線技術学会, Vol. 77, No. 8, 2021.
- (12) Shaoqing Ren, Kaiming He, Ross Girshick, Jian Sun: Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks, arXiv:1506.01497v3, 2016.
- (13) Ross Girshick, Jeff Donahue, Trevor Darrell, Jitendra Malik: Rich feature hierarchies for accurate object detection and semantic segmentation, Computer Vision and Pattern Recognition, arXiv:1311.2524v5, 2014.
- (14) Wei Liu, Dragomir Anguelov, Dumitru Erhan, Christian Szegedy, Scott Reed, Cheng-Yang Fu, Alexander C. Berg: SSD: Single Shot MultiBox Detector, Computer Vision and Pattern Recognition, arXiv:1512.02325, 2016.
- (15) Joseph Redmon, Santosh Divvala, Ross Girshick, Ali Farhadi: You Only Look Once: Unified, Real - Time Object Detection, Computer Vision and Pattern Recognition, arXiv:1804.02767, 2016.
- (16) Zhou, F., Zhao, H., Nie, Z.: Safety Helmet Detection Based on YOLOv5, 2021 IEEE International Conference on Power Electronics, Computer Applications, pp.6-11, 2021.
- (17) GitHub: microsoft/VoTT, 2022 年 5 月 30 日, <https://github.com/microsoft/VoTT>
- (18) GitHub: rafaelpadilla/Object-Detection-Metrics, 2022 年 5 月 30 日, <https://github.com/rafaelpadilla/Object-Detection-Metrics/blob/master/README.md>
- (19) 吉岡淳, 近土真由美, 加藤正太, 島崎直也, 鈴木博子, 西本千尋, 松田智美, 保科政美, 芝本隆: 無線通信を利用した輸液ポンプ遠隔監視システムの研究開発意義について, 医工学治療, Vol. 32, No. 3, pp.153-158, 2020.