臨床技術

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田沼隆夫¹ 小林達明² 高屋英知³ 鈴木大吾¹井上美香¹ 吉川達生¹ 小林泰之⁴論文受付
2020 年 9 月 9 日論文受理
2021 年 4 月 14 日

Code No. 1031

¹ 聖マリアンナ医科大学病院画像センター² 聖マリアンナ医科大学大学院医学研究科先端生体画像情報研究講座³ 慶応義塾大学大学院理工学研究科⁴ 聖マリアンナ医科大学大学院医学研究科医療情報処理技術応用分野

緒言

体内手術用ガーゼ遺残防止策は、手術開始前、体腔閉鎖前、筋層閉鎖前、手術終了後などに行われる目視のガーゼカウントが基本であるが、必要に応じて術後 X 線撮影による確認が行われる¹⁾。日本医療機能評価機構、医療事故情報収集等事業の医療安全情報 No.153 によれば、2016 年 1 月 1 日から 2019 年 3 月 31 日まで

に発生した 57 件の手術用ガーゼ遺残事故のうち、X 線撮影による確認が行われているにもかかわらず見落とされていた事例が 26 件/43 件あったことが報告されている²⁾。X 線撮影でガーゼが見落とされた要因としては、術部が撮影範囲に含まれていなかった、ガーゼカウントが正しく行えなかったなどが挙げられ、中には、ガーゼが残存している画像を見た経験がなく知

Object Detection Model Utilizing Deep Learning to Identify Retained Surgical Gauze in the Body on Postoperative Radiography: Phantom Study

Takao Tanuma,^{1*} Tatsuki Kobayashi,² Eichu Takaya,³ Daigo Suzuki,¹ Mika Inoue,¹ Tatsuo Yoshikawa,¹ and Yasuyuki Kobayashi⁴¹ Imaging Center, St. Marianna University School of Medicine Hospital² Advanced Biomedical Imaging Informatics, St. Marianna University Graduate School³ Graduate School of Science and Technology, Keio University⁴ Department of Medical Information and Communication Technology Research, St. Marianna University Graduate School

Received September 9, 2020; Revision accepted April 14, 2021

Code No. 1031

Summary

Purpose: Foreign bodies such as a surgical gauze can be retained in the body after surgery and in some cases cannot be detected by postoperative radiography. The aim of this study was to develop an object detection model capable of postsurgical detection of retained gauze in the body. The object detection model used deep learning using abdominal radiographs, and a phantom study was performed to evaluate the ability of the model to automatically detect retained surgical gauze. **Materials and Methods:** The object detection model was constructed using a Single Shot MultiBox Detector (SSD) 300. In total, 268 abdominal phantom images were used: 180 gauze images were used as training data, 20 gauze images were used as validation data, and an additional 34 gauze images and 34 non-gauze images were used as test data. To evaluate the performance of the object detection model, a confusion matrix was created and the accuracy and sensitivity were calculated. **Result:** True-positive (TP) rate, true-negative (TN) rate, false-positive (FP) rate, and false-negative (FN) rate were 0.92, 1.00, 0.00, and 0.08, respectively. Accuracy was 0.96, and sensitivity was 0.92. **Conclusion:** The object detection model could detect surgical gauze on abdominal phantom images with a high accuracy and sensitivity.

Key words: surgical gauze, deep learning, phantom study, radiography, object detection

*Corresponding author

Fig. 1 Examples of phantom layouts.
(a) Non-gauze images, (b) Gauze images

識が不足していた，椎体前面にあり X 線画像ではわかりづらかったなど，実際はガーゼが画像に描出されているにもかかわらず見逃された例もあった³⁾．これらの事例のうち，経験不足などの人的な要因により起こったものに関しては，ガーゼ検知支援システムがあれば防止することができた可能性がある．

手術用ガーゼ遺残防止に関連する過去の研究では，ガーゼカウントを支援するシステムとして，IC タグをガーゼそれぞれに設け，無線で読み取って管理する技術⁴⁾や，外科手術の状況を撮影した術野のモニタリング画像からガーゼを検出する技術⁵⁾が提案されているが，医療現場に広く普及しているとはいえない．また近年では，ガーゼ検知の課題に対処するために深層学習技術が採用されはじめている．単純 X 線を用いた物体検出分野では，術後ガーゼ検知の製品化に成功している例がある⁶⁾．

それでもなお，術後ガーゼ遺残検知に深層学習を用いた研究報告は少なく，ガーゼのような特殊な異物を画像から検出するタスクに焦点を当てた場合，最大の課題となるのは異物の検出能向上であり，そこには高い偽陽性率や偽陰性率を低減させるような課題が残っていると考えられる．例えば，実臨床で取得される術中あるいは術後の腹部 X 線画像はさまざまなチューブやデバイスなどの体内外に存在する障害陰影を含んでおり，手術用ガーゼのみを検出することは困難であると予想される．更に，障害陰影がない(手術用ガーゼのみを添付した)腹部 X 線画像から手術用ガーゼの検出可否を検討した基礎的な報告もないため，実臨床画像を対象とした検討以前に多くの課題が存在すると

考えられる．また，深層学習には多量の学習用画像データが必要となるが，ガーゼ遺残画像は数が非常に少ない．これらの背景から，本研究では X 線撮影による術後ガーゼ遺残防止支援に向けて，腹部ファントム画像を用いて物体検出モデルを開発し，手術用ガーゼ自動検知のための基礎的な検討を行った．

1. 方法

1-1 学習データの作成

対象部位は体内遺残が最も多い腹部とし，深層学習のための学習データには腹部ファントム画像を使用した．ガーゼが画像内に含まれる(ガーゼあり)画像を計 234 枚，含まれない(ガーゼなし)画像を計 34 枚取得した．学習データの取得に使用した機器，器具を以下に示す．

- ・一般 X 線撮影装置 キヤノンメディカルシステムズ(栃木)製 MRAD-A50S RADREX
- ・医用 X 線高圧装置 キヤノンメディカルシステムズ製 KXO-50SS
- ・フラットパネルディテクタ キヤノン(東京)製 CXDI-701C Wireless
- ・画像処理ワークステーション キヤノン製 CXDI Control Software NE ver. 2.19.1.6
- ・体幹部ファントム 京都科学社(京都)製 PBU-60
- ・ガーゼ 白十字(東京)製 BK サバキガーゼ

画像取得時のファントム配置は，画像中央の配置以外にも，横隔膜または骨盤を多く含む，第一，第二斜位，および左右回転など(最大 20 度程度)，ランダムに撮影された(Fig. 1)．ガーゼあり画像はファントムの

Fig. 2 SSD model (Reference 7, Fig. 2).

The SSD model has a deep learning model called VGG16 as its core. VGG16 plays an important role in retaining features for solving classification tasks. Networks following after VGG16 were designed with convolutional layers to improve detectabilities from the rectangle.

上に乾燥したガーゼ(1~2枚)を丸めて配置し、形や位置をランダムに変えて取得した。ガーゼなし画像はガーゼありの場合からガーゼを取り除き、同じ幾何学的配置で取得した。撮影条件はすべて同一とし、管電圧 90 kVp, 管電流 200 mA, 撮影時間 50 ms, 焦点-受像器間距離 130 cm とした。画像処理パラメータは、ガーゼやカテーテルなどを過度に強調した処理ではなく、通常診療で用いるパラメータ(LUT タイプ SB, エッジ強調 5, エッジ周波数 5, コントラストブースト 4, DR 圧縮処理低輝度 5, 同高輝度 7, ノイズ低減処理 10)とした。

1-2 画像処理

撮影にて取得された画像は、患者名などが画像上に記録されているため、この領域はモデル入力前にカットした。

1-3 ガーゼ検出モデルの開発

開発環境のハードウェアは NVIDIA Corporation 社 (Santa Clara, CA, USA) 製 DGX Station を用いた。プログラミング言語は Python, 深層学習ライブラリは Keras, 開発環境に JupyterLab を用いてモデルの開発を行った。物体検出モデルは Visual Object Classes Challenge 2012 (VOC2012) データセットにて学習済みの SSD300⁷⁾ (Fig. 2) を用いて転移学習を行った。出力層はラベリングされるクラス数に調整した。損失関数は SSD モデル用に調整された SSDLoss 関数を利用した。エポック数はいくつかの数値で試し、ほぼ収束するまでに 120 程度かかったため、120 とした。検出された領域がガーゼである確率(probability)の閾値は Liu ら⁷⁾ を参考に 0.5 とした。またこの閾値は自然画

像の物体検出において標準的な値である。

モデル開発用の画像データは、トレーニングデータとしてガーゼあり画像を 180 枚、検証データとしてガーゼあり画像を 20 枚、テストデータとしてガーゼあり画像とガーゼなし画像をそれぞれ 34 枚用意した。

1-4 ラベリングとアノテーション

ラベリングに利用するクラス名は「gauze」のみとし、その他は「background」として処理されるよう設定した。アノテーションは専用ソフトの labelImg を用いて、矩形のアノテーション領域を各画像内のガーゼ周囲に設定し、xml ファイルとして保存した (Fig. 3)。

1-5 ガーゼ検出モデルの評価

開発した検出モデルにてテストデータからガーゼを検出し、それらの検出結果から混同行列を作成した。また、正解率、感度、特異度、適合率、F 値を算出した。

2. 結果

学習過程を Fig. 4 に示す。

評価関数である SSDLoss 関数の値は学習 (エポック) が進むにつれて小さくなり、エポックが 76 で最小値を示した。したがって、エポックが 76 における重み係数をモデルの重み係数として採用した。Table 1 にモデルの評価結果として混同行列、Table 2 にモデル評価精度を示す。

2-1 ガーゼの検出に成功した例

成功例では、正解ラベルとほぼ同じ位置に予測された関心領域が計算された (Fig. 5)。

Fig. 3 Example of annotation using the labelling.
Grand truth area is annotated by a rectangle as a label. Label annotation is named “gauze”. Each gauze is annotated one by one.

Fig. 4 Training results.
The loss is SSD loss. The val-loss is SSD loss for validation dataset. At epoch 76, SSD loss is the smallest.

Table 1 Confusion matrix

Actual model	Predicted model	
	Gauze	Non-gauze
Gauze	33/36	0/34
Non-gauze	3/36	34/34

Table 2 Evaluation results

True-positive rate	0.917
True-negative rate	1.000
False-positive rate	0.000
False-negative rate	0.083
Accuracy	0.957
Sensitibity	0.917
Specificity	1.000
Precision	1.000
F-score	0.957

Fig. 5 Test results—Successful cases.

The dark gray rectangle is the grand truth label. The light gray rectangle is predicted results. The left figure shows that the gauze near the diaphragm was detected accurately. The middle figure shows that the gauze at the edge of the image area was detected. The right figure shows that the gauze that overlaps with the vertebra was detected accurately.

Fig. 6 Test results—Failure cases.

This model could not detect a gauze at the bottom of the image (left). The middle figure shows that the model could not detect all gauzes. An example of captured multiple gauze as one gauze (right).

2-2 ガーゼの検出に失敗した例

34 例中の 1 例はまったく検出することができなかったが、この画像はガーゼ位置が画像の端に一部欠けるように映り込んでいるものであった (Fig. 6, No. 220). また、二つ以上のガーゼが存在する場合で、ガーゼ同士が離れている場合に、片方のみ検出できないケースがあった (Fig. 6, No. 231). 一方で、ガーゼ同士が近い場合は、複数のガーゼが一つのガーゼとして検出された例があった (Fig. 6, No. 233).

3. 考 察

本研究では、術後 X 線撮影によるガーゼ遺残防止の基礎検証として腹部ファントム画像を用いてガーゼ検出モデルを開発し、高い精度でガーゼを検出することができた (正解率 0.96, 感度 0.92). ガーゼあり画像

であるにもかかわらず検出できなかった 1 例は、ガーゼが画像の端に位置し、かつガーゼの大半が撮影範囲から外れていた (Fig. 6 No. 220). ガーゼが画像の端に位置する他のケースでは、ガーゼ全体が撮影範囲に含まれているケースと比べ、モデルが出力する probability が低くなる傾向が確認された (Fig. 7). 一方で、欠損 (+) かつ画像の端 (+) であっても probability が高いケースも確認された (Fig. 7, No. 201). これは probability が低かったケースと比べ、比較的欠損の領域が少なく、正解ラベルと予測された関心領域の重なりを評価する指標である Intersection over Union (IoU) を物体検出時に十分算出できたためと考えられる.

緒言で述べたように、ガーゼ遺残事故の背景・要因に術部が撮影範囲に入っていなかった例もあるため、

Fig. 7 Cases of a gauze missing out of the imaging area located at the edge of the image.

欠損(+)かつ画像の端(+)の画像は現実にも起こりうると考えられる。ガーゼが端にあり一部しか撮影されていない例を本提案手法にて解決するためには、ミラーリング技術の利用が考えられる。この技術は、存在しない画像の端に、上下(または左右)逆になった画像を合成して処理する方法である。画像の4辺を合成して辺縁部のみを拡張するため、IoUが十分に計算できないようなガーゼ描出不良の画像でも、モデルが特徴を拾い上げることを助ける可能性がある⁸⁾。また、複数ガーゼがある場合は、複数のガーゼを一つのガーゼとして検出した例があった。実際には、ガーゼカウントとの整合などのため、個々のガーゼが正確に捕捉されなければならない場合もある。更なる精度改善のためには、モデルの入力画像のマトリクスサイズを大きくして解像度を上げるなどの工夫が必要であると考えられる。また、臨床用ガーゼ検出モデルの開発のためには、ファントムにはない臨床画像固有の複雑な物体検出タスクを解決するモデルの開発が必要である。そこで今後の検討として、①今回はSSDのみの検討であったため、RCNN⁹⁾やyolo¹⁰⁾などの代表的なネットワークでの比較②教師画像数は少ないことが予測されるため教師画像を模擬的に作成する技術の開発③今回は計算機リソースなどの課題もあり未実施で

あったが、深層学習において一般的に行われるグリッドサーチなど、最適なハイパーパラメータの探索④術後X線画像にガーゼやカテーテルなどを過度に強調した処理画像を提供する施設もあるため³⁾、画像処理パラメータの検討、などを考えている。

本研究のリミテーションを以下に示す。①学習データの被写体は単一のファントムであり、骨の形状、臓器や腸管内空気などの配置はすべて同じである②実際の術後X線画像にはドレーンやチューブ、クリップ、セメントビーズの糸などが混在している③学習データ作成時に乾燥したガーゼを用いたが、実際は体内に存在するため血液や体液などが吸着しており、ガーゼのコントラストやサイズが異なる可能性がある④学習データの取得は一般撮影用の臥位テーブル上で行ったが、実際は手術台での撮影であるため環境が異なる。

4. 結 語

われわれはガーゼ遺残防止支援に向けて、臨床応用が可能な深層学習によるガーゼ検出モデルの開発に必要と考えられる基礎的な検討を行った。深層学習を用いた物体検出モデルによる手術用ガーゼ検知を腹部ファントム画像にて検討した結果、画像からガーゼを

検出するタスクに対して正解率 0.96, 感度 0.92 の精度を確認した。一方で, ガーゼが複数ある場合や, 撮影範囲から外れて端に写ってしまったガーゼの検出のための配慮が必要であることが確かめられた。われわれは本検討を足がかりとして, 更なるモデル開発を継続する予定である。

謝 辞

本研究に際しご指導いただいた原田学園経営企画室

人工知能研究開発チームの平原大助氏にこの場をお借りして厚く御礼申し上げます。また, ご協力いただいた皆様に深く感謝いたします。

利益相反

筆頭著者および共著者全員に申告すべき利益相反はない。

参考文献

- 1) 日本手術看護学会 手術看護基準・手順委員会. 第 6 章 患者の安全管理基準. 手術看護業務基準. 日本手術看護学会, 東京, 2017: 45-56.
- 2) 日本医療機能評価機構 医療事故防止事業部. 医療事故情報収集等事業 医療安全情報 No.153. 日本医療機能評価機構, 2019. http://www.med-safe.jp/pdf/med-safe_153.pdf (参照 2020-08-14).
- 3) 日本医療機能評価機構 医療事故防止事業部. 医療事故情報収集等事業 第 54 回報告書. 日本医療機能評価機構, 2018: 74-89. http://www.med-safe.jp/pdf/report_54.pdf (参照 2020-08-14).
- 4) 志水英二, ウラセ株式会社, 福井県. 手術用ガーゼ及びその管理システム. 特開 2013-188278. 2013-09-26.
- 5) EIZO 株式会社. ガーゼ検出システム. 特開 2018-068863. 2018-05-10.
- 6) 富士フイルム株式会社. TOPICS 富士フイルムが超軽量移動型デジタル X 線撮影装置に搭載する AI 技術を活用した“手術用ガーゼの認識機能”を発売—術後の体内遺残物の確認作業をサポートし, 見落とし防止に貢献—. INNERVISION 2020; 35(5): 91.
- 7) Liu W, Anguelov D, Erhan D, et al. SSD: Single Shot MultiBox Detector. arXiv: 1512.02325[v5], 2016.
- 8) Cireşan DC, Giusti A, Gambardella LM, et al. Deep neural networks segment neuronal membranes in electron microscopy images. NIPS'12: Proceedings of the 25th International Conference on Neural Information Processing Systems 2012: 2; 2843-2851.
- 9) Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation. IEEE Conference on Computer Vision and Pattern Recognition 2014: 580-587.
- 10) Redmon J, Divvala S, Girshick R, et al. You only look once: Unified, real-time object detection. IEEE Conference on Computer Vision and Pattern Recognition 2016; 779-788.

問合せ先

〒216-8511 川崎市宮前区菅生 2 丁目 16-1
聖マリアンナ医科大学病院画像センター 田沼隆夫