

수술 동영상에서의 인공지능을 사용한 출혈 검출 연구

정시연¹ · 김영재² · 김광기^{2,3*}

¹가천대학교 공과대학 산업공학과, ²가천대학교 IT융합대학 의공학과

³가천융합의과학원(GAIHST) 융합의과학과

A Study on the Bleeding Detection Using Artificial Intelligence in Surgery Video

Si Yeon Jeong¹, Young Jae Kim² and Kwang Gi Kim^{2,3*}

¹Department of Industrial Management Engineering, College of Engineering, Gachon University

²Department of Biomedical Engineering, College of IT Convergence, Gachon University

³Department of Health Sciences and Technology, Gachon Advanced Institute for Health & Sciences and Technology (GAIHST)
(Manuscript received 29 April 2023 ; revised 23 June 2023 ; accepted 26 June 2023)

Abstract: Recently, many studies have introduced artificial intelligence systems in the surgical process to reduce the incidence and mortality of complications in patients. Bleeding is a major cause of operative mortality and complications. However, there have been few studies conducted on detecting bleeding in surgical videos. To advance the development of deep learning models for detecting intraoperative hemorrhage, three models have been trained and compared; such as, YOLOv5, RetinaNet50, and RetinaNet101. We collected 1,016 bleeding images extracted from five surgical videos. The ground truths were labeled based on agreement from two specialists. To train and evaluate models, we divided the datasets into training data, validation data, and test data. For training, 812 images (80%) were selected from the dataset. Another 102 images (10%) were used for evaluation and the remaining 102 images (10%) were used as the evaluation data. The three main metrics used to evaluate performance are precision, recall, and false positive per image (FPPI). Based on the evaluation metrics, RetinaNet101 achieved the best detection results out of the three models (Precision rate of 0.99 ± 0.01 , Recall rate of 0.93 ± 0.02 , and FPPI of 0.01 ± 0.01). The information on the bleeding detected in surgical videos can be quickly transmitted to the operating room, improving patient outcomes.

Key words: Bleeding detection, Surgery video, Deep learning, Object detection, Computer aided diagnosis (CAD)

I. 서 론

1. 서론

출혈은 수술 중에 흔히 발생하지만 많은 출혈이 발생할 경우 합병증 발생률과 사망률이 높아진다[1-5]. 혈관 수술의 경우

사망률이 5-8%에서 20%로 높아지고[6] 복강경 수술은 6-13%로 높아지며[7] 심장 수술은 환자의 3.6-4.2%는 재수술이 필요하다[8,9]. 혈액이 많이 손실되어 출혈성 쇼크가 발생하거나 완전히 혈액을 잃어 사망하는 데까지 걸리는 시간은 불과 몇 시간 이므로 출혈을 조기에 감지하는 것이 중요하다[10].

장기 수술은 집중력과 판단력에 영향을 줄 수 있다. 피로감으로 인해 의사들이 출혈을 인지하는 시점이 늦어지면 신속한 대응이 지연된다. 이러한 문제를 해결하기 위해 수술 중 컴퓨터 보조 진단 시스템(Computer Aided Diagnosis, CAD) 도입이 필요하다. 최근 의료 분야에서 병변을 검출하는 컴퓨터 보조진단 시스템은 컴퓨터 비전(Computer Vision) 알고리즘에 인공지능(Artificial Intelligence) 알고리즘(Algorithm)

*Corresponding Author: Kwang Gi Kim

Department of Biomedical Engineering, College of IT Convergence, Gachon University, Incheon 21565, Republic of Korea
Tel: +82-10-3393-4544

E-mail: kimkg@gachon.ac.kr

본 연구는 2023년도 산업통상자원부 및 산업기술평가관리원(KEIT) 연구비 지원(K_G012001187801, 인공지능 기반 영상분석 기술을 탑재한 영상진단 의료기기 개발)과 경기도의 경기도 지역협력연구센터 사업의 일환으로 수행하였음[GRRC-가천2020(B02), AI 기반 의료 영상 분석].

을 도입하고 있다[11]. 특히 딥러닝(Deep Learning) 알고리즘은 자동으로 추출된 특징에 따라 동작하므로 수동으로 추출된 특징을 기반으로 하는 기존의 컴퓨터 버전 알고리즘과 초기 머신러닝(Machine Learning) 알고리즘과 비교하여 일반화된 특징을 학습한다[12-14].

수술 동영상 관련 연구에서 수술 도구 검출 및 수술 과정을 인식하는 연구는 많이 이루어진 반면 출혈을 검출하는 연구는 거의 없다. 또한 딥러닝을 이용한 출혈 검출 연구는 대부분 무선 캡슐 영상(Wireless Capsule Endoscopy, WCE)에서 이루어졌다. 하지만 무선 캡슐 영상은 다양한 장기들이 포함된 수술 동영상과는 달리 단순한 내벽 구조만을 포함하며 출혈 영역을 제외하고 간(Liver)과 같이 적색 레벨(Level)이 높은 조직이 없다. 수술 동영상과 무선 캡슐 영상은 촬영된 내부 구조, 조명, 출혈 영역의 등의 환경이 다르기 때문에 수술 동영상 속 출혈 영역과는 다른 특징을 가지고 있다. 따라서 수술 동영상을 대상으로 한 딥러닝 모델 학습이 필요하다.

따라서 본 연구는 수술동영상에서 출혈을 조기에 검출하기 위해 다섯 종류의 수술 동영상 데이터로 세 종류의 딥러닝 모델을 학습시킨 후 모델 간 출혈 검출 능력을 비교 평가한다.

2. 관련 연구

Alvaro 등은 수술 동영상에서 추출된 이미지에서 화소 단위로 출혈을 검출하였다. 대상 이미지의 RGB 공간에서 화소와 이미지 전체의 B/R값과 G/R값을 비교하여 출혈 영역을 이루는 화소인지 배경영역을 이루는 화소인지 분류한 결과

정확도(Accuracy)는 0.89이고 재현율(Recall)은 0.73인 결과를 도출했다[15]. Takayuki 등은 수술 동영상을 대상으로 머신 러닝 알고리즘을 사용하여 출혈을 검출하였다. RGB공간과 HSV 공간에서 추출한 색상 특징 값(Color Feature)으로 SVM(Support Vector Machine)을 학습시켜 최적의 분류 파라미터(Parameter)를 얻고자 했다. 그 결과 정확도는 0.96이고 재현율은 0.98인 결과를 얻었다[16].

하지만 성능 지표 값이 낮고[15] 높더라도 10명의 환자 데이터로 도출된 결론이므로 신뢰성이 떨어진다[16]. 또한 머신러닝(Machine Learning) 방식은 데이터에서 수동으로 추출된 특징 값(Feature)을 기반으로 학습하기 때문에 다양한 패턴의 특징을 자동으로 추출하여 학습하는 딥러닝(Deep Learning) 방식에 비해 강건하지 않다[12-14]. 따라서 최근에는 딥러닝을 도입한 병변 검출 연구가 이루어지고 있다[17-18]. Sunitha 등은 무선 캡슐 영상에서 얻은 이미지를 증강하고 연구 목적에 맞게 수정된 AlexNet 딥러닝 모델에서 이미지의 특징을 추출하였다. 출혈 부위 검출은 SVM 알고리즘을 이용하였으며 정확도 0.95, 재현율 0.95인 결과를 도출했다[18].

II. 연구 방법

1. 학습 환경

본 연구에서는 8개의 NVIDIA Tesla A100(NVIDIA, Santa Clara, CA, USA) 그래픽 처리 장치와 AMD EPYC 7513 32-core CPU, 503GB RAM으로 구성된 시스템을 사




그림1. 출혈 검출 모델 학습 흐름도: 데이터 수집, 데이터 레이블링, 데이터 분할, 모델 학습 및 검증, 모델 평가

Fig. 1. Flowchart of Bleeding Detection Model Training: Dataset Collection, Dataset Labeling, Dataset Split, Model Training and Validation, Model Test

용했다. Ubuntu 20.04 운영체제에서 Python(Ver 3.8.15) 및 OpenCV(Ver 4.7.0) 등의 라이브러리와 Pytorch(Ver 1.7.0) 프레임워크를 사용하여 모델을 학습시켰으며 Pandas (Ver 1.5.2) 및 Sklearn(Ver 1.1.1) 등의 라이브러리를 사용해 성능을 평가했다. 데이터 레이블링은 Annovie Software (Ver 1.0, MTEG, Seoul, Republic of Korea)를 활용하였다.

2. 데이터 수집 및 레이블링

본 연구에서는 2021년부터 2022년까지 2년간 인천 소재의 A대학병원에서 수술을 받은 560명 환자의 수술 동영상 수집하였다. 수술은 원위부 위절제술 120건, 우측 결장 절제술 100건, 저위전방 절제술 100건, 근치적전립선 적출술 140건, 자궁내막암 수술 100건을 포함한다. 수술 종류 별 데이터 개수는 그림 1에 확인할 수 있다. 수집된 데이터는 인천 소재의 A대학병원의 임상 시험 심사 위원회(GCIRB 2022-178)의 허가를 받은 후 전문의 정보 및 환자의 개인식별이 가능한 정보를 비식별 처리했다.

이후 전문의가 560건의 영상에서 일반적인 출혈, 혈압이 높은 동맥 혈관이 손상되었을 때 발생하는 혈액 줄기, 출혈을 막지 못했을 때 발생하는 혈액 웅덩이와 같이 3가지 출혈 형태가 포함된 이미지 1,016장을 추출하였다. 그림 2는 본 연구에서 수집한 출혈 형태의 예시를 보여준다. 이미지의 형식은 jpg이며 크기는 720×1820 화소에서 1080×1920 화소 사이이고 화소 당 24개의 비트(bit)를 갖는다. 정답 데이터(Ground Truth, GT)는 2명의 전문의가 합의한 출혈 위치에 박스(Box) 형태로 관심 영역(Region Of Interest, ROI)을 그려 확보하였다.

출혈 검출 모델의 학습 및 검증을 위해 전체 데이터 셋을 8:1:1 비율로 학습 데이터셋(Training Dataset), 검증 데이터셋(Validation Dataset), 테스트 데이터셋(Test Dataset)으로 나누었으며 각각 812장, 102장, 102장으로 이루어져 있다.

3. 출혈 검출 모델

본 연구에서 출혈을 검출하기 위해 사용한 딥러닝 모델 종류는 RetinaNet과 YOLOv5이다. 이미지 분류 네트워크를 적은 개수의 클래스 수를 갖는 데이터셋으로 학습시킬 경우 심각한 과적합(Over Fitting) 현상이 발생하여[19] 일반적으로 비교적 층수가 낮은 모델을 사용한다[20]. 따라서 본 연구는 50개의 층을 가진 RetinaNet50 모델과 101개의 층을 가진 RetinaNet101 모델을 선정하였다. 하지만 속도가 느리다는 단점이 있기 때문에 층수는 비교적 많지만 실시간 객체 검출이 가능한 YOLOv5 모델도 함께 비교 평가하였다. RetinaNet과 YOLOv5 모두 One-stage detector이다. One-stage detector의 기본 구조는 백본(Backbone), 넥(Neck), 헤드(Head)이다. 백본은 입력 이미지에 대한 특징 맵(Feature Map)을 추출하고 넥은 백본에서 추출된 특징 맵을 이용하여 다양한 크기의 특징 피라미드(Feature Pyramid)를 추출한다. 마지막 헤드 부분은 경계 상자, 클래스, 객체 점수를 최종적으로 출력한다. RetinaNet 모델의 백본은 ResNet이고 넥은 FPN(Feature Pyramid Map)이며 자세한 구조는 그림 3a와 같다. RetinaNet은 잔여 학습(Residual Learning)을 통해 레이어(Layer)가 깊은 모델 학습의 정확도를 높였으며 초점 손실(Focal Loss)이라는 손실 함수를 통해 객체와 배경 간 클래스 불균형 문제를 해결했다[21]. 본 연구에서는 ResNet의 레이어 깊이가 50인 모델과 101인 모델을 사용하였다. YOLOv5 모델의 백본은 CSP-Darknet이고 넥은 PANet이며 자세한 구조는 그림 3b와 같다. 백본에서는 Cross Stage Partial (CSP)로 연산량을 줄이고 Spatial Pyramid Pooling(SPP)으로 입력 이미지 크기나 비율에 상관없이 CNN을 적용할 수 있도록 하였으며 넥에서는 Path aggregation network(PAN)을 통해 낮은 수준(Low-Level)의 정보가 온전하게 높은 수준(High-Level)로 전달되어 다양한 크기의 객체 검출에 유리하도록 하였다.

세 종류의 모델 학습에 사용된 파라미터는 공통적으로 배치(Batch) 크기는 16, 초기 학습률은 10^{-5} , 최적화 알고리즘




그림 2. 출혈 레이블링 예시: (a) 일반적인 출혈 (b) 혈압이 높은 동맥 혈관이 손상되었을 때 발생하는 혈액 줄기 (c) 출혈을 막지 못했을 때 발생하는 혈액 웅덩이

Fig. 2. Examples of Bleeding Labeling: (a) normal bleeding (b) blood stem that occurs when arterial blood vessels with high blood pressure are damaged (c) blood pool that occurs without hemostasis





그림 3. 모델 구조: (a) RetinaNet 구조; ResNet을 백본으로 하고 FPN을 넥으로 하며 잔여 학습 기법과 초점 손실 함수를 사용하여 객체 검출 수행. (b) YOLOv5 구조; CSP-Darknet을 백본으로 하고 PANet을 넥으로 하며 CSP, SPP 기법 등을 이용해 객체 검출 수행
Fig. 3. Model Structure: (a) RetinaNet Structure; Using ResNet as the backbone and FPN as the neck, along with residual learning techniques and focal loss function. (b) YOLOv5 Structure; Using CSP-Darknet as the backbone and PANet as the neck, along with CSP and SPP techniques

은 Adam, 에폭(Epoch)은 200으로 설정하였으며 학습률 스케줄러는 RetinaNet50의 경우 reduceLROnPlateau, YOLOv5의 경우 LambdaLR을 사용했다. 그림 1은 본 연구에서 수행한 출혈 검출 모델 학습의 전체적인 흐름을 보여준다.

4. 통계 방법

모델 예측 결과와 정답 데이터를 비교하기 위해 식 (1)을 통해 계산된 다이스 계수(Dice Coefficient)를 사용하였고 모델 성능 평가 지표로는 정밀도(Precision), 재현율, 이미지 당

위양성 개수(False Positive Per Image, FPPI)를 사용하였다. 성능 평가 지표 계산에 사용하기 위해 모델 예측 결과가 출혈이 있는 위치를 올바르게 검출한 경우 진양성(True Positive, TP), 출혈이 아닌 위치를 검출한 경우 위양성(False Positive, FP), 출혈을 검출하지 못한 경우 위음성(False Negative, FN)으로 분류하였다. 정밀도, 재현율, 평균 위양성 개수는 IoU (Intersection over Union)값이 0.1이상인 검출 결과를 대상으로 식 (2), (3), (4), (5)를 이용하여 계산하였다. 정밀도란 모델이 예측한 바운딩 박스(Bounding Box) 중 진양성의

비율을 나타내고 재현율은 실제 출혈 위치의 바운딩 박스 중 진양성의 비율을 나타낸다. 정밀도와 재현율은 서로 상충관계에 있다. 모델이 엄격한 기준으로 예측할 경우 위양성 개수가 줄어들어 정밀도가 높아지지만 위음성 개수가 많아져 재현율이 낮아진다. 반대의 경우에는 위양성 개수가 늘어나 정밀도가 낮아지지만 위음성 개수가 줄어들어 재현율이 높아진다. 따라서 두 지표를 모두 고려하여 모델 성능을 평가했다. 이미지 당 위 양성 개수는 이미지 한 장당 검출된 평균 위양성 개수이다. 오검출 개수를 정량적으로 표현하기 위해 도입하였다.

$$\text{Dice} = \frac{2 \times \text{Area of Overlap}}{\text{Area of Prediction} + \text{Area of Ground Truth}} \quad (1)$$

$$\text{IoU} = \frac{\text{Area of Overlap}}{\text{Area of Union}} \quad (2)$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (3)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (4)$$

$$\text{FPPI} = \frac{\text{FP}}{\text{Number of Images}} \quad (5)$$

컨피던스(Confidence) 점수는 모델이 검출한 객체에 대해 예측한 클래스(Class)가 맞을 확률과 IoU값을 곱한 값으로 검출된 경계상자의 클래스 분류 정확도와 위치 검출 정확도를 함께 볼 수 있는 지표이다.

III. 연구 결과

본 연구에서는 수술 동영상에서 출혈을 검출할 수 있도록 세 개의 모델을 학습시켰고 102장의 테스트 데이터를 사용하여 각 모델의 성능을 비교 평가하였다. 표 1은 세 모델의 성능 평가 결과를 요약한 표로 컨피던스 임계값을 0.1부터 0.9까지 0.1씩 변화시켰을 때 테스트 이미지 102장에서 계산되는 진양성 개수와 위음성 개수 그리고 모델 성능 평가 지표의 평균값과 표준편차와 함께 세 모델의 재현율 평균값 차이의 유의수준을 보여준다. 그림 4는 컨피던스 임계값이 0에서부터 1까지 변할 때 FPPI값에 따른 재현율을 나타낸




그림 4. Free Response Operating Characteristic(FROC) 그래프: 컨피던스 임계값에 따른 재현율과 FPPI의 변화

Fig. 4. Free Response Operating Characteristic (FROC) Graph: The change in recall and FPPI (False Positive Per Image) with respect to confidence threshold variations

FROC 그래프이고 그림 5는 출혈 레이블링 정답 데이터는 초록색 바운딩 박스로, 모델이 검출한 예측 데이터는 붉은색 바운딩 박스로 표시한 결과이다. 그림 4를 보면 FPPI가 0.02로 낮을 때 세 모델의 재현율은 0.80 이상이었고 그림 5b에서 연기로 인해 출혈 부위가 가려진 이미지와 그림 5c에서 출혈 위치에 반사광이 있는 이미지에서 도출된 다이스 계수(Dice Coefficient)는 각각 0.72와 0.50이었다.

성능 평가 결과 표 1에서 세 모델은 재현율에서 차이가 발생했다. 각 모델의 재현율 평균값의 차이가 유의한지 확인하기 위하여 일원배치 분산분석(One-way Analysis of Variance, One-way ANOVA)를 수행한 결과 세 모델의 재현율 평균은 유의미한 차이가 있었다($p < 0.05$).

IV. 고찰 및 결론

본 논문에서는 세 종류의 모델을 선정하여 수술 동영상에서 출혈을 검출할 수 있도록 학습시킨 후 비교 평가했다. 연구에 사용된 모델은 RetinaNet50, RetinaNet101, YOLOv5이었으며 그림 4에서 재현율이 높을 때에도 위양성으로 분류되는 경우가 적었다는 점에서 전반적으로 검출 성능이 높게 도출되었음을 확인할 수 있었다. 그림 5b와 그림 5c에서 세 종류의 모델이 연기 또는 반사광이 있는 이미지에서 출혈을 검출했다는

표 1. 모델 별 성능 평가 비교 표

Table 1. Comparison table of performance assessment result by Models

Model	TP	FN	Precision	Recall	FPPI	p
Yolov5	74.78±15.58	27.22±15.58	0.99±0.01	0.73±0.15	0.01±0.01	
RetinaNet50	85.56±5.66	16.44±5.66	0.99±0.01	0.84±0.05	0.01±0.01	<0.05
RetinaNet101	94.89±2.51	7.11±2.51	0.99±0.01	0.93±0.02	0.01±0.01	




그림 5. 모델 별 출혈 검출 결과(초록색 박스=정답 ROI, 빨간색 박스=예측 ROI) (a) 일반 출혈 검출 결과 (b) 연기로 가려진 이미지에서의 출혈 검출 결과 (c) 빛 반사가 존재하는 이미지에서의 출혈 검출 결과 (d) 복잡도가 큰 이미지에서의 출혈 검출 결과

Fig. 5. Bleeding Detection Results by Models (Green Box= Ground Truth ROI, Red Box=Predicted ROI): (a) bleeding detection in normal image (b) bleeding detection in smoke covered image (c) bleeding detection in image with light reflection (d) bleeding detection in image with high complexity

점에서 본 연구의 딥러닝 방식이 수동적으로 추출된 특징을 기반으로 하는 선행 연구의 컴퓨터 비전 알고리즘과 비교하여 강건하고 일반화된 검출 능력을 가지고 있다는 것을 확인했다.

모델 간 성능 평가 결과 재현율의 평균값에서 유의미한 차이가 발생했으며 RetinaNet101, RetinaNet50, YOLOv5 순으로 높은 평균값이 도출됐다. 세 종류 모델의 성능 차이는 그림 5d와 같이 복잡도가 큰 이미지에서 확인할 수 있었다. 이미지의 복잡도가 클수록 화소 값이 크게 변하는 영역이 출혈 영역으로 특정되지 않고 전 영역에 퍼져 있기 때문에 검출에 난이도가 있던 것으로 판단된다.

딥러닝 모델 학습 시 추출되는 특징 값 개수는 레이어가 깊을수록 많아진다. 관심 대상의 특징 값이 많을수록 검출에 유리하지만 학습 데이터의 특징 값을 과도하게 추출하여 학습할 경우 새로운 데이터에 대한 대응력이 떨어지는 과적합 현상이 발생할 수 있다. YOLOv5의 레이어 개수는 468개로 레이어 개수가 50개인 RetinaNet50보다 9.36배 깊고 레이어 개수가 101인 RetinaNet101보다 4.68배 깊다. YOLOv5 모델은 학습 데이터셋 크기에 비해 레이어 깊이가 깊어 과적합으로 인해 부진한 학습 결과를 도출했다고 판단된다. RetinaNet50은 RetinaNet101보다 레이어 개수가 적기 때문에 충분한 특징 값 개수를 학습하지 못하여 RetinaNet101보다 부진한 결과를 도출했던 것으로 판단된다.

정밀도의 평균값과 이미지 당 위양성 개수에는 유의미한 차이가 도출되지 않았다. 진양성 및 위양성 개수에 있어서는 차이를 보이지 않고 위음성 개수에 차이를 보였다는 것을 의

미한다. 이는 모델 별 성능은 출혈이라고 판단되기 까다로운 이미지에 상대적으로 높은 컨피던스를 부여할 수 있는지에 따라 차이가 발생하는 것으로 판단된다. 따라서 성능을 향상을 위해서는 향후 출혈로 판단하기 어려운 이미지들을 위주로 모델을 강화하는 연구도 유의미할 것으로 생각된다.

본 연구에서 사용한 수술 동영상 데이터 종류는 5가지로 적으며 이미지를 대상으로 모델을 학습 및 평가하여 실시간으로 수술 영상에 적용(Inference)하지 못했다는 한계가 있다. 따라서 향후 다양한 종류의 수술 영상을 확보하여 모델을 학습시킨 후 실시간 적용 기술을 도입한다면 실제 수술 상황에서 출혈을 최소화할 수 있는 보조 진단 시스템을 개발에 도움이 될 수 있을 것이며 본 연구를 실시간 검출이 가능하도록 하면 임상에 도입할 수 있는 시스템으로 발전할 수 있을 것이다. 또한 본 연구에서는 세 종류의 모델을 비교 평가하였지만 레이어 깊이에 따라 다수의 모델을 선정하여 레이어에 따른 성능 차이를 비교하여도 유의미한 연구가 될 것이라고 기대한다.

References

- [1] Shah A, Ralmer AJR, Klein AA. Strategies to minimize intraoperative blood loss during major surgery. *Br J Surg.* 2020;107(2):26-38.
- [2] Wu WC, Smith TS, Henderson WG, Eaton CB, Poses RM, Uttley G, Mor V, Sharma SC, Vezeridis M, Khuri SF, Friedmann PD. Operative blood loss, blood transfusion, and 30-day mortality in older patients after major noncardiac surgery. *Ann Surg.* 2010;252(1):11-17.

- [3] Smilowitz NR, Oberweis BS, Nukala S, Rosenberg A, Zhao S, Xu J, Stuchin S, Lorio R, Errico T, Radford MJ, Berger JS. Association between anemia, bleeding, and transfusion with long-term mortality following noncardiac surgery. *Am J Med.* 2016;129(3):315-323.
- [4] Christensen MC, Dziewior F, Kempel A, von Heymann C. Increased chest tube drainage is independently associated with adverse outcome after cardiac surgery. *J Cardiothorac Vasc Anesth.* 2012;26(1):46-51.
- [5] Stokes ME, Ye X, Shah M, Mercaldi K, Reynolds MW, Rupnow MF, Hammond J. Impact of bleeding-related complications and/or blood product transfusions on hospital costs in inpatient surgical patients. *BMC Health Serv Res.* 2011;11:135.
- [6] Marietta M, Facchini L, Pedrazzi P, Busani S, Torelli G. Pathophysiology of bleeding in surgery. *Transplant Proc.* 2006;38(3):812-814.
- [7] Asfour V, Smythe E, Attia R. Vascular injury at laparoscopy: a guide to management. *J Obstet Gynaecol.* 2018;38(5):598-606.
- [8] Rady MY, Ryan T, Starr NJ. Perioperative determinants of morbidity and mortality in elderly patients undergoing cardiac surgery. *Crit Care Med.* 1998;26(225).
- [9] Vincent JL, Baron J-F, Reinhart K, et al. Anemia and blood transfusion in critically ill patients. *JAMA.* 2002;288(1499).
- [10] Tran A, Matar M, Lampron J, et al. Early identification of patients requiring massive transfusion, embolization or hemostatic surgery for traumatic hemorrhage: A systematic review and meta-analysis. *J Trauma Acute Care Surg.* 2018;84(3):505-516.
- [11] Pesapane F, Codari M, Sardanelli F. Artificial intelligence in medical imaging: Threat or opportunity? Radiologists again at the forefront of innovation in medicine. *Eur Radiol Exp.* 2018;2(1):35.
- [12] Kawaguchi F, Kaelbling LP, Bengio Y. Generalization in Deep Learning. *Cambridge tracts in computing*, 2017;1:112-148.
- [13] Andrew RB. Universal approximation bounds for superpositions of a sigmoidal function. *IEEE Trans Inf Theory*, 1993;39(3):930-945.
- [14] Leshno M, Lin VY, Pinkus A, et al. Multilayer feedforward networks with a nonpolynomial activation function can approximate any function. *Neural Netw*, 1993;6(6):861-867.
- [15] Garcia-Martinez A, Vicente-Samper JM, Sabater-Navarro JM. Automatic detection of surgical hemorrhage using computer vision. *Artif Intell Med.* 2017;78:55-60.
- [16] Okamoto T, Ohnishi T, Kawahira, H, Dergachyava O, Jannin P, Haneishi H. Real-time identification of blood regions for hemostasis support in laparoscopic surgery. *SIVIP.* 2019; 13:405-412.
- [17] Zhou XY, Guo Y, Shen M, Yang GZ. Application of artificial intelligence in surgery. *Front Med.* 2020;14(4):417-430.
- [18] Sunitha S, Sujatha SS. An Improved Bleeding Detection Method for Wireless Capsule Endoscopy (WCE) Images Based on AlexNet. *ICPSC.* 2021;11-15.
- [19] Hawkins DM. The Problem of Overfitting. *J Chem Inf Comput Sci.* 2004;44(1):1-12.
- [20] Kwak D, Choi J, Sungjin L. A Method of the Breast Cancer Image Diagnosis Using Artificial Intelligence Medical Images Recognition Technology Network. *J-KICS.* 2023;48(2):216-226.
- [21] Lin TY, Goyal P, Girshick R, He K, Dollar P. Focal Loss for Dense Object Detection. *ICCV.* 2017;2980-2988.