



Received: 2023/05/31
Revised: 2023/06/13
Accepted: 2023/06/29
Published: 2023/06/30

***Corresponding Author:**

Dooyoung Kim

Dept. of Artificial Intelligence, Republic of Korea
Naval Academy
1 Jungwon-ro, Jinhae-gu, Changwon-si,
Gyungsangnam-do, 51704, Republic of Korea
Tel: +82-2-907-5246
E-mail: dykim07@navy.ac.kr

상륙작전 시 대규모 외상환자의 신속 분류를 위한 CNN 모델

Use of CNN for Rapid Classification of Massive Trauma Patients During Amphibious Operations

박태진¹, 이건수¹, 이재준¹, 이준서¹, 김두영^{2*}

¹해군사관학교 사이버과학과 사관생도

²해군소령/해군사관학교 인공지능학과 부교수

Teajin Park¹, Gunsoo Lee¹, Jaejoon Lee¹, Junseo Lee¹,
Dooyoung Kim^{2*}

¹Midshipman, Dept. of Cyber Science, Republic of Korea Naval Academy

²LCDR ROK Navy/Associate professor, Dept. of Artificial Intelligence,
Republic of Korea Naval Academy

Abstract

본 논문에서는 대규모 외상환자가 발생하는 상륙작전에서 신속한 중증도 분류를 지원하기 위한 CNN 기반의 딥러닝 모델을 제안한다. 먼저 외상환자 학습데이터를 생성하기 위해 Unity 기반의 가상환경을 구축하여 다양한 환자 이미지를 생성하였다. CNN을 이용한 이미지 기반 환자 분류 모델을 설계하였고, 앞서 생성한 가상 이미지를 이용하여 학습을 진행하였다. 실험결과 97%의 정확도로 부상 부위를 분류하였다.

In this paper, we propose a CNN-based deep learning model for rapid classification in amphibious operations where massive trauma patients occur. First, we built a virtual environment based on Unity to generate various patient images for trauma patient training data. We designed an image-based classification model using CNN and proceeded with training using the generated images. As a result of the experiment, we classified the injury site with an accuracy of 97%.

Keywords

중증도 분류(Triage),
상륙작전(Amphibious Operation),
합성곱 신경망(Convolutional Neural Network),
복수 라벨 분류(Multi-label Classification)

1. 서론

상륙작전은 “함정, 주정 또는 항공기에 탑승한 해군과 상륙군이 해양을 통하여 적 해안에 군사력을 투사하는 공격작전”을 말한다[1]. 이러한 상륙작전은 감시장비, 해안포, 기뢰 등의 다양한 방어수단이 강구된 적 해안의 확보를 목표로 진행됨에 따라 다수의 병력 손실이 동반된다.

2차 세계대전 노르망디 상륙작전 당시, 오마하 해변에 상륙한 미 29보병사단 16연대 3대대 2중대의 경우 198명의 해병 중 상륙 직후 4분 30초 만에 196명이 전사하는 등 전체 미군 상륙병력 5만여 명 중 약 3,000여 명이 D-Day 하루 만에 전사하였다. 따라서 부상 병력, 특히 외상환자에 대한 신속한 의무지원은 상륙작전의 성공적인 수행과 장차 작전을 위한 전력 보존에 필수적인 과업이다. 이에 따라 우리 군의 독도급 대형 상륙함에는 수술실 등의 의무 시설이 갖춰져 있으며, 이와 더불어 전시 병원선으로 활용 가능한 다목적 훈련함인 한산도함을 운영 중이다.

전.평시 대량의 외상환자가 발생했을 때 의무자원의 효율적 분배 및 신속한 환자 처치를 위해 중증도 분류(triage)를 수행한다[2-4]. 이는 재난 상황이나 다수의 환자가 발생한 사고현장에서 각 환자의 부상 심각도를 바탕으로 처치에 대한 우선순위를 효과적으로 결정하기 위

한 절차를 말한다. 대한민국 소방청의 중증도 분류 지침인 재난현장 표준작전절차 402[3]에 따르면, “긴급환자”는 수분 혹은 단시간 내 즉각적인 응급처치와 이송이 필요한 환자, “응급환자”는 수 시간 이내 응급처치를 시행해야 하는 환자, “비응급 환자”는 즉각적인 처치가 필요하지 않은 가벼운 손상으로 보행 가능한 환자, “지연 환자”는 이미 사망하였거나 생존 가능성이 없는 환자를 말한다.

이러한 중증도 분류 절차는 환자 분류, 응급처치, 병원 이송, 원내 처치 등의 치료 과정에서 가장 최초에 이루어지는 의료 행위이다[2,3]. 따라서 DMAT(disaster medical assistance team) 등 현장 의무인력의 신속하고 정확한 분류는 이후 의무자원의 최적 배치를 위해 매우 중요하다.

이러한 중요성에도 불구하고, 현재의 중증도 분류 행위는 전문 교육을 이수한 의료인력에 전적으로 의존하는 상황이다[2]. 상륙작전의 경우, 해안 교두보 확보 전까지 전문적인 의료 행위는 해상 함정으로 제한되며, 동시 투입 가능한 인적 물적 자원 또한 한계가 있다. 따라서 초기 중증도 분류에 투입되는 의무인력의 부하를 덜어줄 수 있는 지원 시스템이 필요하다.

본 논문에서는 상륙작전 상황에서 대규모 외상환자의 신속한 초기 분류를 위한 CNN(convolutional neural network)[5,6] 기반의 모델을 제안한다. 제안한 기법은 상륙함정의 환자 이송통로 상부 또는 의무 헬기 상부에 설치된 저해상도 카메라로 촬영한 환자의 이미지를 바탕으로 외상 부위를 1차로 파악함으로써 의무인력이 최적의 의무자원을 할당할 수 있도록 보조하는 것을 목적으로 한다.

우리 연구의 핵심은 다음과 같다. (1) Unity[7] 기반의 가상환경을 구축하여 전시 발생 가능한 대량 외상환자의 이미지 데이터 세트를 구축하였다. (2) 입력된 이미지를 바탕으로 외상환자의 부상 부위를 추정할 수 있는 CNN 기반의 딥러닝 모델을 제작하였다. (3) 실험을 통하여 제안한 모델의 성능을 검증하였다.

이후 논문의 주요 내용은 다음과 같다. 2장에서 외상환자 데이터 세트 생성을 위한 가상환경과 생성된 데이터 세트의 특징에 대해 설명하였다. 3장에서 외상환자 부상 부위 예측을 위한 딥러닝 모델의 구조에 대해 설명하고, 4장에서는 실험을 통해 제한한 모델의 성능을 검증하였다. 5장에서는 논문의 의의와 향후 연구 방향에 대해 서술하였다.

2. 학습 데이터 생성

제안한 기법의 학습을 위해서는 대량의 외상환자 데이터가 필수적이다. 그러나 현실 세계에서 중증외상환자의 이미지 데이터 세트를 구축하는 것은 실현 가능성이나 윤리적 문제뿐만 아니라 현행 의료법[8] 및 개인정보 보호법[9]으로 인해 어렵다. 따라서, 본 연구에서는 대표적인 게임 엔진인 Unity[7]를 사용하여 가상환경을 구축하였고, 이를 통해 상륙작전 시 발생 가능한 외상환자의 데이터 세트를 구축하였다.

먼저 전시 상황을 가정하여 외상환자의 복장과 부상 유형을 결정하였다. 위장 군복, 방탄모, 방탄조끼, 군화 등 보병 표준 장비를 착용한 군 장병의 가상 인체 모형을 생성하였다. 이때 장구의 색상 및 위장 패턴을 다양하게 지정하였다. 이와 더불어 촬영 환경 및 카메라 특성의 변화를 모사하기 위해 광원 위치, 모핑, 회전, zoom, 이미지 크기변환, 밝기, 배경 변화, 블러링, 색상변환 등 다양한 변화를 가상환경에 적용하였다.

부상 유형은 총상 및 폭발로 인해 사지 절단 환자가 다수일 것으로 가정하여, 좌·우측 팔과 다리의 소실 여부를 구분하였다. 가정 시 두부와 흉부는 방탄복, 방탄복 등 보호 장구를 고려하여 대상에서 제외하였다. 팔은 상박, 하박, 손의 손실을 모사하였고, 다리는 허벅지, 종아리, 발의 손실을 모사하였다. 부위별 각 부상 부위의 표기 및 약어는 Table 1과 같다. 부상 정도는 실제 전장에서 부상 상황을 가정하여, 복수의 부상이 동시에 발생할 수 있다고 가정하였다. 이와 더불어 상부가 절단된 경우 이에 따르는 중부와 하부도 동시에 소실된다고 가정하였다. 예를 들어 왼팔 상박이 소실된 경우 왼팔 하박과 손도 함께 소실되도록 데이터를 생성하였다.

Table 1. Injured cases for trauma dataset

Body parts	Upper	Middle	lower
Left arm	Left upper arm (LUA)	Left forearm (LFA)	hand (LH)
Right arm	Right upper arm (RUA)	Right forearm (RFA)	Right hand (RH)
Left leg	Left upper leg (LUL)	Left lower leg (LLL)	Left foot (LF)
Right leg	Right upper leg (RUL)	Right lower leg (RLL)	Right foot (RF)

이를 통해 생성된 외상환자 데이터 세트의 특성은 다

음과 같다. 먼저 입력값 x 는 환자를 상부에서 촬영한 이미지 데이터로 가로 640, 세로 480픽셀(pixel) 크기의 3채널(channel) RGB 값을 가지는 PNG 형식으로 제작하였다. 출력값 y 는 총 12개 부위의 부상을 표현하는 12차원의 벡터이며, 벡터의 각 요소는 해당 부위 부상 시 1, 아닐 경우 0의 이진값을 가진다. 이때, 다수의 부상 상황을 고려하여 값이 1인 요소가 하나 이상인 multi-label 형태로 정의하였다.

위 과정을 통해 총 50,000개의 학습 데이터를 생성하였으며, 본 논문에서는 이 중 35,000개를 학습 데이터, 15,000개를 테스트 데이터로 사용하였다. Fig. 1은 생성된 학습 데이터 중 일부이다.

3. 외상환자 분류 모델

입력값이 이미지임을 고려하여, 이미지 분류를 위한 대표적인 딥러닝 기법인 CNN을 기반으로 분류 모델을 제작하였다. 제안한 모델은 크게 특징 추출기와 분류기로 구성되며, 전체 네트워크 구조와 초매개변수(hyper parameters)는 Table 2와 같다.

특징 추출기는 입력 이미지에서 환자의 부상 부위를 구별하기 위한 특징을 추출하기 위해 사용된다. 총 15개의 CNN 블록으로 구성되었으며, 각 블록은 2~4개의

CNN 계층과 하나의 max pooling[10] 계층으로 구분된다. 각 CNN 계층은 공통으로 3x3 커널(kernel)을 사용하였으며, stride 및 padding 값은 1, 활성화 함수로 ReLU[11]를 사용하였다. 이때 과적합 방지와 스케일링을 위해 각 블록의 마지막 부분에 max pooling 계층을 3x3 커널 및 stride 값 2로 설정하여 삽입하였다.

분류기는 총 네 개의 전(全)연결 신경망(FCNN, fully connected neural network)으로 구성되어있다. 앞서 특징 추출기를 통해 추출된 입력 이미지의 특징은 분류기를 통과하여 12차원의 벡터로 변환된다. 출력 벡터의 각 요소의 값은 sigmoid[12] 함수를 통과하여 0에서 1 사이의 값을 가지게 되며, 이는 해당 부위가 소실되었을 확률을 의미한다.

학습을 위해 네트워크의 모든 매개변수는 Glorot 초기화 기법[13]을 사용하여 초기화하였다. 학습 시 Adam 최적화 기법[14]에 학습률 0.0001을 적용하였으며, 손실함수는 binary cross entropy[15]를 사용하였다. 각 배치는 64개의 데이터로 구성되어있으며, 총 epoch는 50회 실시하였고, 조기 멈춤(early stopping)을 적용하여 가장 좋은 모델을 선정하였다. 하드웨어는 NVIDIA의 DGX-A100을 사용하였으며, 모든 네트워크는 Pytorch를 이용하여 구현하였다. 학습에 사용한 초매개변수는 모두 실험을 통해 선정하였다.

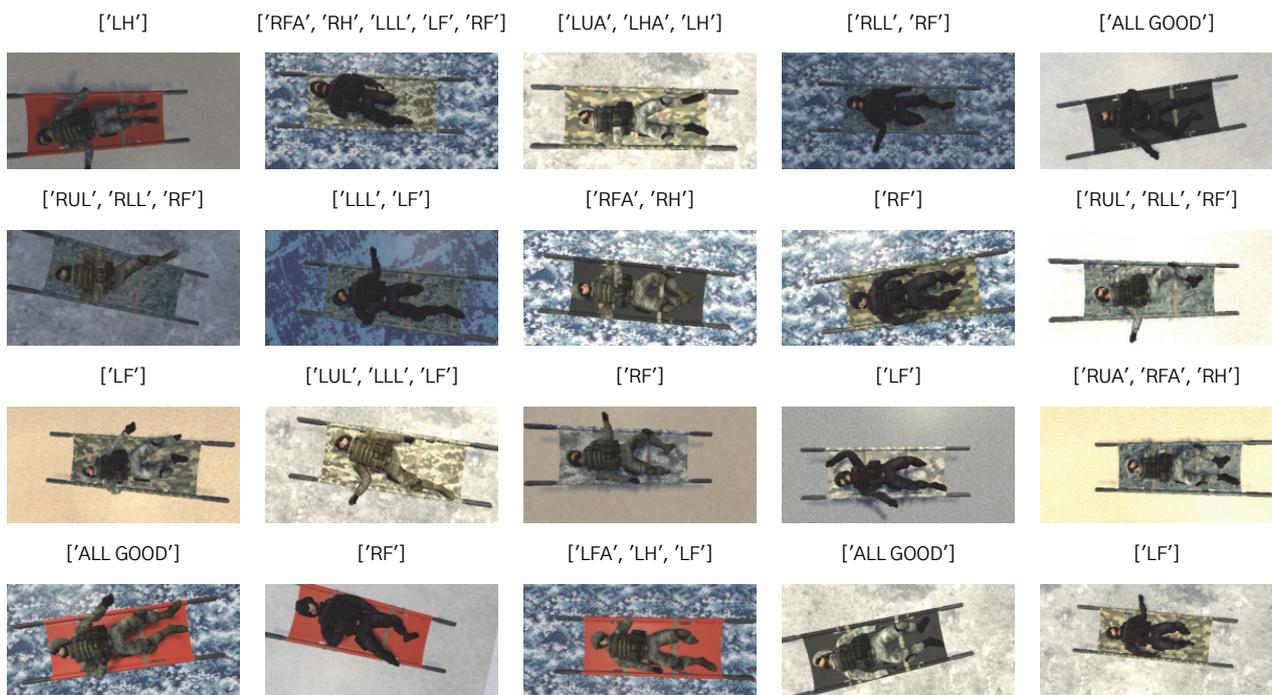


Fig. 1. Examples of trauma dataset

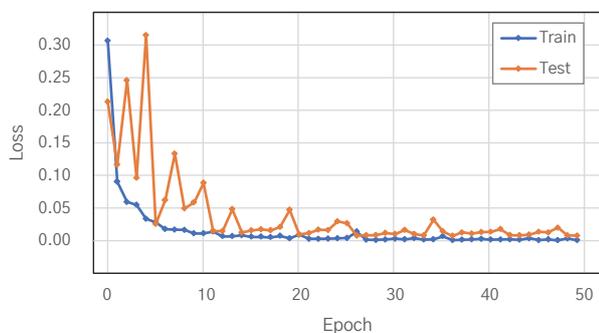
4. 실험결과

Fig. 2는 제안한 모델의 학습 곡선이다. 평가 시 정확도(accuracy)는 라벨의 모든 값을 정확하게 예측한 비율(exact-match ratio)로 계산하였다. 학습 초기에는

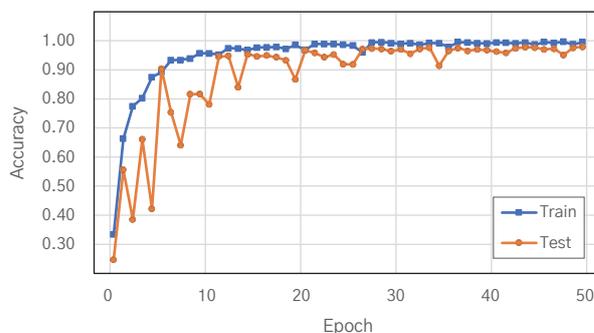
테스트 데이터 세트에 대한 손실률(loss)과 정확도(accuracy)가 불안정한 모습을 보이나, epoch 20회 이후로 안정적인 값을 보인다. 학습 종료 시 테스트 데이터 세트에 대한 최종 정확도(exact-match ratio)는 97 %이다.

Table 2. Network structure and hyper-parameters

Layers	Hyper-parameters
Conv1	channel = 64, kernel = 3×3, stride = 1, padding = 1, Batch Normalization, ReLU
Conv2	channel = 128, kernel = 3×3, stride = 1, padding = 1, Batch Normalization, ReLU
Max Pooling	kernel = 2×2, stride = 2
Conv3	channel = 128, kernel = 3×3, stride = 1, padding = 1, Batch Normalization, ReLU
Conv4	channel = 128, kernel = 3×3, stride = 1, padding = 1, Batch Normalization, ReLU
Conv5	channel = 128, kernel = 3×3, stride = 1, padding = 1, Batch Normalization, ReLU
Max Pooling	kernel = 2×2, stride = 2
Conv6	channel = 128, kernel = 3×3, stride = 1, padding = 1, Batch Normalization, ReLU
Conv7	channel = 128, kernel = 3×3, stride = 1, padding = 1, Batch Normalization, ReLU
Conv8	channel = 128, kernel = 3×3, stride = 1, padding = 1, Batch Normalization, ReLU
Max Pooling	kernel = 2×2, stride = 2
Conv9	channel = 64, kernel = 3×3, stride = 1, padding = 1, Batch Normalization, ReLU
Conv10	channel = 64, kernel = 3×3, stride = 1, padding = 1, Batch Normalization, ReLU
Conv11	channel = 64, kernel = 3×3, stride = 1, padding = 1, Batch Normalization, ReLU
Max Pooling	kernel = 2×2, stride = 2
Conv12	channel = 64, kernel = 3×3, stride = 1, padding = 1, Batch Normalization, ReLU
Conv13	channel = 32, kernel = 3×3, stride = 1, padding = 1, Batch Normalization, ReLU
Conv14	channel = 32, kernel = 3×3, stride = 1, padding = 1, Batch Normalization, ReLU
Conv15	channel = 32, kernel = 3×3, stride = 1, padding = 1, Batch Normalization, ReLU
Max Pooling	kernel = 2×2, stride = 2
FCNN1	in = 1600, out = 256, ReLU
FCNN2	in = 256, out = 128, ReLU
FCNN3	in = 128, out = 64, ReLU
FCNN3	in = 64, out = 12, Sigmoid



(a) Loss



(b) Accuracy

Fig. 2. Learning curve of the proposed mode

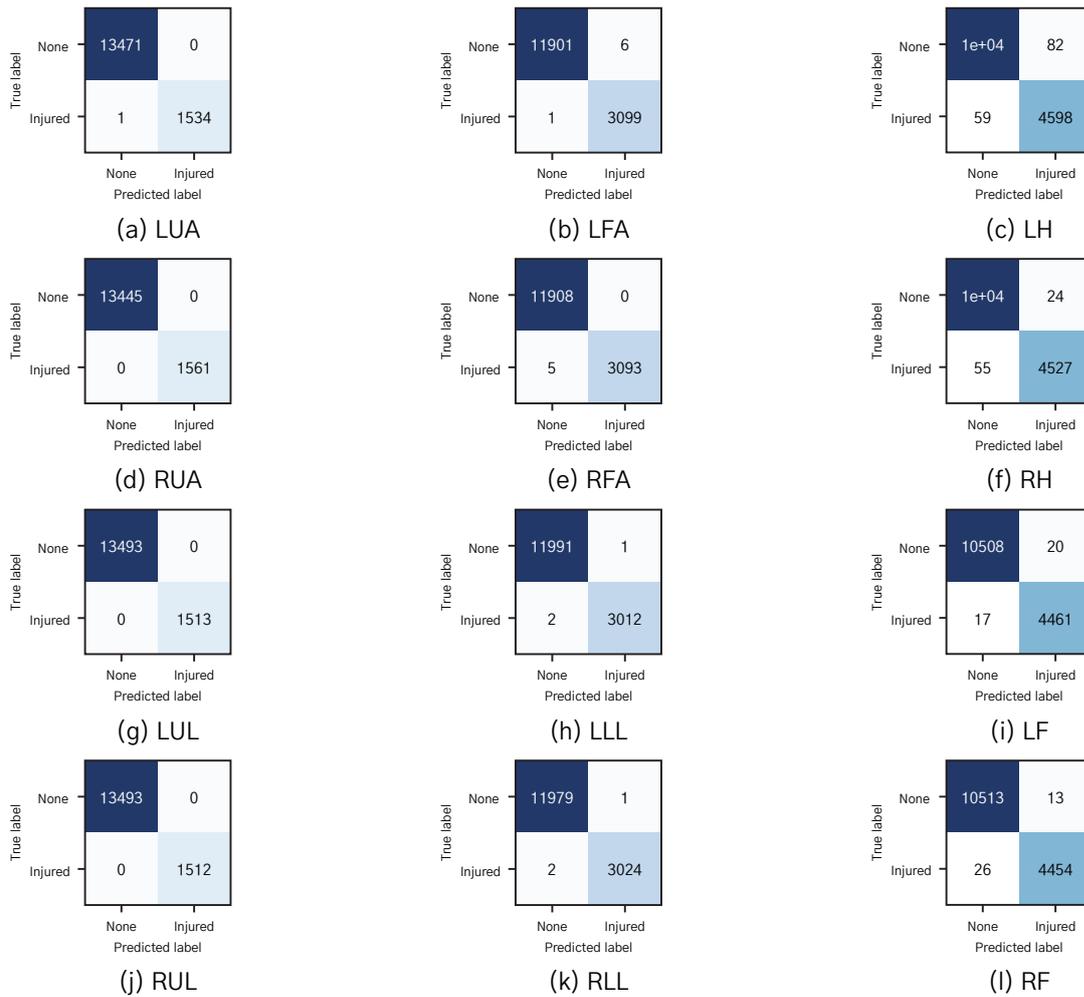


Fig. 3. Confusion matrix of the proposed model

부위별 예측 성능을 확인하고자 예측 벡터와 실제 벡터에서 부위별 데이터를 추출하여 결과를 도식화하였다. Fig. 3는 부위별 예측 성능을 혼동행렬(confusion matrix)로 도식화한 그림이다. 각 그림에서 x축은 제안한 모델의 예측 결과를, y축은 실제 부상 여부를 표현한다. 그림에서 확인할 수 있듯이, 제안한 모델은 개별 부상 위치를 정확하게 분류하였다.

Table 3은 부위별 예측 성능의 정밀도(precision), 재현율(recall), F1-score의 결과이다. 앞서 확인한 Fig. 3의 결과와 함께 유효숫자 범위 내에서 정확하게 부상 위치를 식별하였음을 확인할 수 있다.

다만 두 가지 분석에서, 좌측 손(LH), 우측 손(RH)의 경우 일부 오분류(mis-classification)가 발생하였다. 해당 오류 분석 결과 대부분 Fig. 4와 같이 배경과 군복의 패턴이나 색상이 같은 경우에서 발생하였다. 특히 손의 경우 다른 부위와 다르게 들것에서 벗어나는 경우가 데이터에 존재하기에 발생한 것으로 판단된다.

Table 3. Injured cases for trauma dataset

Body parts	Precision	Recall	F1
LUA	1.00	1.00	1.00
LFA	1.00	1.00	1.00
LH	0.99	0.99	0.99
RUA	1.00	1.00	1.00
RFA	1.00	1.00	1.00
RH	0.99	0.99	0.99
LUL	1.00	1.00	1.00
LLL	1.00	1.00	1.00
LF	1.00	1.00	1.00
RUL	1.00	1.00	1.00
RLL	1.00	1.00	1.00
RF	1.00	1.00	1.00

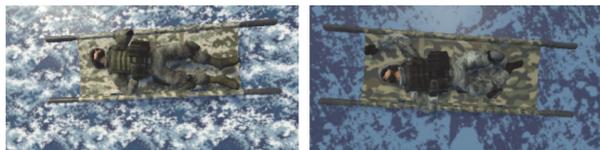


Fig. 4. Examples of miss classification

5. 결론

앞서 분석한 바와 같이, 다수의 외상환자가 단시간에 발생하는 상륙작전에서 의무자원의 효과적인 배분은 중요한 과업이며, 이러한 배분에 있어 중증도 분류의 신속성과 정확성은 반드시 확보되어야 한다.

본 논문에서는 딥러닝 기반의 이미지 분류 기술 중 하나인 CNN을 활용하여 외상환자의 1차 분류를 수행함으로써 의무인력의 노력을 감소시키는 방식을 제안하였다. 특히 논문에서 해결하고자 하는 문제가 실제 자료를 수집할 수 없는 상황을 극복하기 위해 Unity 기반의 가상환경을 구축하고 이를 통해 중증외상 환자의 가상 이미지를 대량으로 생산하여 외상환자 데이터 세트를 구축하였다.

또한, 분류를 위한 CNN 기반의 모델을 제안하였고, 앞서 만들어진 외상환자 데이터 세트를 이용하여 모델의 학습과 테스트를 진행한 결과 97%의 정확도로 모든 부상을 정확하게 예측하였고, 부상 부위별 예측 정확도는 99%의 정확도로 예측한 양손을 제외한 나머지 부위는 100% 정확하게 예측하였다.

중증도 분류는 의료인의 고유 영역으로 제안한 모델로 모든 것을 대체할 수 없다. 실제 상황에서는 호흡, 맥박, 반사 반응 등 의료인력의 경험과 진단을 바탕으로 이루어져야 한다. 다만 전시 등 의료인력의 한계를 초과하는 대량의 외상환자가 발생하는 상황에서 한 명의 생명이라도 더 소생시키기 위해서는 현장 의무인력의 업무량 경감을 위한 대책이 필요하다. 본 연구는 이미지라는 제한된 정보 내에서 딥러닝 기술을 이용한 외상환자 초기 분류를 시도하였음에 의의가 있으며, 가상데이터라는 한계를 극복하기 위해 향후 실제 외상환자 데이터를 이용한 전이 학습 등으로 연구를 확장하고자 한다.

참고문헌

- [1] 합동·연합작전 군사용어사전, 합동참모본부, 2004, p. 224.
- [2] 윤지한, “재난현장에서의 다수사상자 중증도 분류에 대한 인식과 전문교육훈련의 필요성에 관한 연구,” 국내석사학위논문 경북대학교 수사과학대학원, 2014, 대구.
- [3] 소방청, 재난현장표준작전절차(SOP), 소방청, pp. 151-152.
- [4] Robert A. De Lorenzo, MC FS USA, Improving Combat Casualty Care and Field Medicine: Focus on the Military Medic, *Military Medicine*, Vol. 162, No. 4, April 1997, pp. 268-272, <https://doi.org/10.1093/milmed/162.4.268>
- [5] Su-Rak Son, Byung-Kwan Lee, Son-Kweon Sim, Yi-Na Jeong, “A Design of Passenger Detection and Sharing System(PDSS) to support the Driving (Decision) of an Autonomous Vehicles,” *Journal of Korea Institute of Information, Electronics, and Communication Technology*, Vol. 13, No. 2, 2020, pp. 138-144.
- [6] Robert A. De Lorenzo, MC FS USA, Improving Combat Casualty Care and Field Medicine: Focus on the Military Medic, *Military Medicine*, Vol. 162, No. 4, April 1997, pp. 268-272, <https://doi.org/10.1093/milmed/162.4.268>
- [7] Unity game engine, www.unity.com
- [8] 대한민국 법률 제19421호, 「의료법」 제 19조(정보누설금지), 대한민국 국가법령정보센터.
- [9] 대한민국 법률 제16930호, 「개인정보보호법」 제15조(개인정보의 수집·이용), 대한민국 국가법령정보센터.
- [10] J. Nagi et al., “Max-pooling convolutional neural networks for vision-based hand gesture recognition,” 2011 IEEE International Conference on Signal and Image Processing Applications (ICSIPA), Kuala Lumpur, Malaysia, 2011, pp. 342-347, doi: 10.1109/ICSIPA.2011.6144164.
- [11] Agarap, A. F. Deep learning using rectified linear units (relu). *ArXiv Preprint ArXiv:1803.08375*, 2018.
- [12] Goodfellow, Ian, Yoshua Bengio, and Aaron Courville. *Deep learning*. MIT Press, 2016. p. 7.
- [13] Glorot, Xavier, and Yoshua Bengio, “Understanding the difficulty of training deep feedforward neural networks,” *Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics, JMLR Workshop and Conference Proceedings*, 2010.
- [14] Kingma, Diederik P., and Jimmy Ba, “Adam: A method for stochastic optimization,” *arXiv preprint arXiv:1412.6980*, 2014.
- [15] Goodfellow, Ian, Yoshua Bengio, and Aaron Courville. *Deep learning*, MIT Press, 2016, p. 73.