

&lt;원저&gt;

## 일반엑스선검사 교육용 시뮬레이터 개발을 위한 기계학습 분류모델 비교

이인자<sup>1)</sup>·박채연<sup>1)</sup>·이준호<sup>2)</sup><sup>1)</sup>동남보건대학교 방사선학과 · <sup>2)</sup>범부처전주기의료기기연구개발사업단 사업화지원팀

## Comparison of Machine Learning Classification Models for the Development of Simulators for General X-ray Examination Education

In-Ja Lee<sup>1)</sup>·Chae-Yeon Park<sup>1)</sup>·Jun-Ho Lee<sup>2)</sup><sup>1)</sup>Department of Radiological Technology, Dongnam Health University<sup>2)</sup>Business Support Team, Korea Medical Device Development Fund

**Abstract** In this study, the applicability of machine learning for the development of a simulator for general X-ray examination education is evaluated. To this end, k-nearest neighbor(kNN), support vector machine(SVM) and neural network(NN) classification models are analyzed to present the most suitable model by analyzing the results. Image data was obtained by taking 100 photos each corresponding to Posterior anterior(PA), Posterior anterior oblique(Obl), Lateral(Lat), Fan lateral(Fan lat). 70% of the acquired 400 image data were used as training sets for learning machine learning models and 30% were used as test sets for evaluation, and prediction model was constructed for right-handed PA, Obl, Lat, Fan lat image classification. Based on the data set, after constructing the classification model using the kNN, SVM, and NN models, each model was compared through an error matrix. As a result of the evaluation, the accuracy of kNN was 0.967 area under curve(AUC) was 0.993, and the accuracy of SVM was 0.992 AUC was 1.000. The accuracy of NN was 0.992 and AUC was 0.999, which was slightly lower in kNN, but all three models recorded high accuracy and AUC. In this study, right-handed PA, Obl, Lat, Fan lat images were classified and predicted using the machine learning classification models, kNN, SVM, and NN models. The prediction showed that SVM and NN were the same at 0.992, and AUC was similar at 1.000 and 0.999, indicating that both models showed high predictive power and were applicable to educational simulators.

**Key Words:** General X-ray Examination, Education, Simulator, Machine Learning, Radiological Technology Student

**중심 단어:** 일반엑스선검사, 교육, 시뮬레이터, 기계학습, 방사선학과 재학생

## I. 서론

질병관리청 2020년 정책연구용역에 의하면 2019년 기준 국내 총 의료방사선 검사 사용량은 약 3.74억 건으로, 2016년 사용량인 3.12억 건에 비하여 약 20% 증가하였으며 연평균 약 6.2%씩 증가한 것으로 나타났다. 이중 일반엑스선검사 사용량은 2016년 2.25억 건에서 2019년 2.68억 건으로

약 19% 증가하였으며 연평균 약 6.1%씩 증가한 것으로 나타났다[1]. 이처럼 진단용 방사선 검사 건수는 해마다 증가하고 있다. 진단용 방사선 검사 건수가 증가하는 추세에 따라 학교에서의 방사선 검사 실습 교육이 중요해지고 있다. 방사선사 면허 소지자는 꾸준히 증가하고 있으며 2020년 방사선사 면허시험은 2,810명이 지원하여 2,736명이 응시하였고 1,897명이 합격하였다[2].

This work was supported by the research grant of the Dongnam Health University.

Corresponding author: Jun-Ho Lee, Business Support Team, Korea Medical Device Development Fund, 5F, 39, Sejong-daero, Jung-gu, Seoul, 04513, Republic of Korea /Tel: +82-2-6328-0366 / E-mail: jhlee@kmdf.org

Received 23 December 2021; Revised 23 January 2022; Accepted 4 March 2022

Copyright ©2022 by The Korean Journal of Radiological Science and Technology

방사선 검사 건수의 증가와 더불어 방사선사 면허 소지자가 꾸준히 증가하는 추세에서 교내 실습 교육의 필요성이 증가하고 있다[2]. 방사선 교육 전문가 집단은 체계적인 실습 교육을 통하여 교육의 질을 높일 수 있다고 주장하고 있으며, 보건계열 방사선학과는 양질의 방사선사를 양성하기 위하여 일반엑스선검사 실습을 정규 교과목으로 편성하여 운영하고 있다[3].

방사선학과 실습 교육은 이론 교육의 확장과 임상 적응을 위하여 중요하게 다루어지고 있지만, 방사선을 이용한 실습 장비는 고가이며 인체 방사선 조사에 대한 법적 문제 등으로 인하여 일반엑스선검사 실습 교육을 진행하는 데 한계가 있다[4].

진단용 방사선 검사에서 숙련된 의료기술을 갖추기 위한 장치 조작 교육은 매우 중요하다. 그러나 일부 대학의 경우 학생은 수시출입자에 해당하게 되므로 진단용 방사선 발생 장치를 직접 조작할 수 없다. 따라서 교육 현장에서는 원활한 현장 실습을 위하여 방사선 발생이 없는 교육용 시뮬레이터의 필요성이 대두되고 있다. 현실적인 한계를 극복한 시뮬레이터 등의 교육 도구가 개발되어 활용된다면 학습자들의 교육 효과는 커질 것이다[5,6].

기계학습은 학습원리 상 일반엑스선검사 교육용 시뮬레이터에 적합하다. 일반엑스선검사 교육용 시뮬레이터는 이미지 촬영 후 기계학습 모델을 통한 분류를 통하여 촬영된 이미지를 예측하고 예측된 이미지에 해당하는 방사선 영상을 화면에 나타내는 과정으로 작동되는데 타 방사선 검사와 다르게 육안으로 확인 가능한 검사 부위를 투영하는 방식이기 때문이다.

연구는 일반엑스선검사 교육용 시뮬레이터 개발에서 기계학습 기법의 적용 가능성을 평가해보고자 한다. 또한, k-최근접 이웃(k-nearest neighbor; kNN), 서포트 벡터 머신(Support vector machine; SVM), 신경망(Neural network; NN) 등 다양한 모델을 사용하고 분석하여 가장 적합한 모델을 제시하고자 한다.

## II. 대상 및 방법

### 1. 데이터 세트(Data set)

연구를 진행하기 위하여 경기도 소재 대학교 학생들의 동의를 얻어 Fig. 1과 같이 오른손 후전방향(Posterior anterior; PA) 검사, 후전사방향(Posterior anterior oblique; Obl) 검사, 측방향(Lateral; Lat) 검사, 부채꼴 측방향(Fan

lateral; Fan lat) 검사에 해당하는 사진을 각 100장씩 촬영하여 이미지 데이터를 획득하였다. 실제 엑스선검사와 동일한 자세를 취한 후 Fig. 2와 같이 50 cm의 촬영거리에서 10 × 12인치 카세트에 맞게 상·하 방향으로 사진을 촬영하였다. 획득한 400개 이미지 데이터의 70%는 기계학습 모델의 학습을 위한 훈련 세트로 사용하였고, 30%는 평가를 위한 테스트 세트로 사용하였다.




Fig. 1. Hand images used in study



Fig. 2. Fixed holder for photography

### 2. 분류모델 및 평가

연구는 오른손 PA, Obl, Lat, Fan lat 이미지의 분류를 위하여 Fig. 3과 같은 예측 모델을 구성하였다. 데이터 세트를 기준으로 kNN, SVM, NN 모델을 사용하여 분류 모델 구성 후 오차 행렬을 통하여 각 모델을 비교하였다. 본 연구의 분류 모델 개발을 위하여 사용된 소프트웨어는 Orange3 3.30.2으로 오픈소스 Python 기반의 데이터 과학, 통계, 시각화, 기계학습 등에 사용되고 있다. Orange3는 탐색적 정성적 데이터 분석 및 대화형 데이터 시각화를 위한 시각적 프로그래밍 프론트 엔드가 특징이다. 기계학습 모델은 분류 및 판별과 결과값 추정으로 나눌 수 있다[7]. 본 연구는 분류를 위하여 kNN, SVM, NN 모델을 사용하였고, 분류모델 평가를 위하여 정확도(Accuracy), F1 스코어(F1 score), 정밀도(Precision), 재현율(Recall), AUC(Area under curve)을 산출하여 비교하였다.

정확도는 모델이 데이터를 얼마나 정확하게 분류했는지에 대한 평가 지표이며, 평가하는데 사용된 총 데이터 중에서 올바르게 분류한 데이터의 비율을 나타낸다. F1 스코어는 정밀도와 재현율의 조화평균으로 정밀도와 재현율을 고려한 평가 지표이다. 정밀도는 정답으로 예측한 데이터 중 실제 정답 데이터의 비율이며, 재현율은 실제 정답 데이터 중 정답으로 예측한 비율이다. 각 평가 지표는 0과 1 사이의 값을 가지며 1에 가까울수록 좋은 성능을 나타내는 모델이다. 각 평가 지표는 Eq. (1)~(4)와 같다.

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad \text{Eq. 1}$$

$$F1\ score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad \text{Eq. 2}$$

$$Precision = \frac{TP}{TP + FP} \quad \text{Eq. 3}$$

$$Recall = \frac{TP}{TP + FN} \quad \text{Eq. 4}$$

여기서 정답으로 예측하고 정답인 경우 TP(True positive), 오답으로 예측하고 오답인 경우 TN(True negative), 정답으로 예측했으나 오답인 경우 FP(False positive), 오답으로 예측했으나 정답인 경우 FN(False negative)이라 한다.

### 3. 기계학습 모델

기계학습은 데이터 패턴을 학습하여 결과를 예측하는 기법으로 지도학습(Supervised learning), 비 지도학습

(Un-supervised learning), 강화학습(Reinforcement learning)으로 나눌 수 있다[8]. 이 중 지도학습은 명시적인 정답이 있는 데이터가 주어진 상태에서 학습하는 기계학습 방식이다. 대표적인 유형인 분류는 학습 데이터로 주어진 데이터를 기계학습 모델로 학습해 모델을 생성하고, 생성된 모델에 새로운 데이터가 주어졌을 때 미지의 값을 예측하는 것이다[9]. 본 연구는 분류 지도학습을 위하여 kNN, SVM, NN 모델을 사용하였다.

#### 1) kNN

kNN은 근접 거리를 기준으로 하는 최소 근접(Nearest neighbor) 모델로 사용자가 직접 정의하는 변수인 k에 따라 데이터 사이의 거리를 기반으로 가까운 k개 데이터의 투표를 통해 분류를 진행한다. 이때 데이터들간의 거리는 Euclidean, Manhattan 등 다양한 거리 계산 방법을 활용할 수 있다.

#### 2) SVM

SVM은 개별 클래스 간의 최대 분류 마진을 효과적으로 찾아주는 모델로 학습 자료를 두 개의 집단으로 분리시키는 함수인 초평면(Hyper-plane)을 추정하는 것이다. 이러한 평면은 무수히 존재할 수 있지만, 두 집단 사이의 유클리드 거리를 최대화하도록 제한을 두면 하나의 유일한 평면이 해가 된다. 이 평면을 최적의 분류 초평면(Optimal hyper-plane)이라 하며 이를 중심으로 클래스를 이진 분류하게 된다[10].

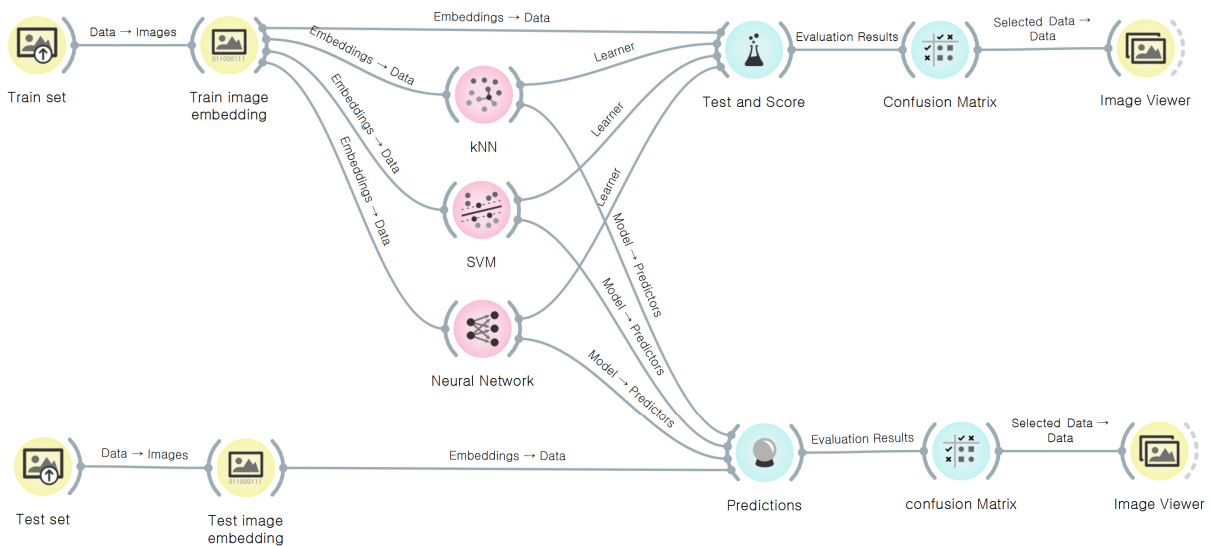


Fig. 3. Predicted model

## 3) NN

NN은 기계학습과 인지과학에서 생물학의 신경망에서 영감을 얻은 통계학적 학습 모델이다. 인공신경망은 시냅스의 결합으로 네트워크를 형성한 인공 뉴런이 학습을 통해 시냅스의 결합 세기를 변화시켜, 문제 해결 능력을 가지는 모델 전반을 가리킨다. 입력에 대하여 각 뉴런이 독립적으로 동작하는 처리기의 역할을 하고 출력하기 때문에 병렬성이 뛰어나고, 연결선에 정보가 분산되어 있기 때문에 일부 뉴런에 문제가 발생해도 전체 시스템에 큰 영향을 주지 않으며 주어진 환경에 대한 학습능력이 있다.

### III. 결과

#### 1. 모델 평가

오른손 이미지의 분류를 위하여 훈련 데이터를 활용하여 kNN, SVM, NN 분류모델을 구축하였다. 생성한 모델에 테스트 데이터를 적용하여 Table 1과 같이 분류 성능평가를 하였다. kNN의 정확도는 0.967 AUC는 0.993으로 나타났으며

SVM의 정확도는 0.992 AUC는 1.000으로 나타났으며, NN의 정확도는 0.992, AUC는 0.999로 나타났으며

#### 2. kNN 성능평가

오른손 PA, Obl, Lat, Fan lat 이미지 각 30장을 사용한 테스트 세트 데이터 120장을 기반으로 한 kNN의 오차 행렬은 Table 2와 같다. PA는 30장을 예측하였고, 30장을 PA로 예측하여 100%의 정확도를 나타냈다. Fan lat은 30장을 예측하였고, 28장은 정확히 예측하였으나 2장을 Obl로 예측하여 93.333%로 나타냈다. Lat은 31장을 예측하였고, 30장은 정확히 예측하였으나 1장을 Fan lat로 예측하여 96.774%로 나타냈다. Obl은 29장을 예측하였고, 28장은 정확히 예측하였으나 1장을 Fan lat로 예측하여 96.552%의 정확도를 나타냈다.

#### 3. SVM 성능평가

테스트 세트 데이터 120장을 기반으로 한 SVM의 오차행렬은 Table 3과 같다. PA는 30장을 예측하였고, 30장을 PA로 예측하여 100%의 정확도를 나타냈다. Fan lat은 29장을

**Table 1.** Result of prediction model evaluation

Model	Accuracy	F1 score	Precision	Recall	AUC
kNN	0.967	0.967	0.967	0.967	0.993
SVM	0.992	0.992	0.992	0.992	1.000
NN	0.992	0.992	0.992	0.992	0.999

**Table 2.** Confusion matrix of kNN

True \ Predicted	Predicted				Total
	PA	Fan lat	Lat	Obl	
PA	30	0	0	0	30
Fan lat	0	28	1	1	30
Lat	0	0	30	0	30
Obl	0	2	0	28	30
Total	30	30	31	29	120

**Table 3.** Confusion matrix of SVM

True \ Predicted	Predicted				Total
	PA	Fan lat	Lat	Obl	
PA	30	0	0	0	30
Fan lat	0	29	0	1	30
Lat	0	0	30	0	30
Obl	0	0	0	30	30
Total	30	29	30	31	120

**Table 4.** Confusion matrix of NN

True \ Predicted	Predicted					Total
	PA	Fan lat	Lat	Obl		
PA	30	0	0	0	0	30
Fan lat	0	29	0	0	1	30
Lat	0	0	30	0	0	30
Obl	0	0	0	0	30	30
Total	30	29	30	30	31	120

예측하였고, 29장을 정확히 예측하여 100%로 나타났다. Lat은 30장을 예측하였고, 30장을 정확히 예측하여 100%로 나타났다. Obl은 31장을 예측하였고, 30장은 정확히 예측하였으나 1장을 Fan lat로 예측하여 96.774%의 정확도를 나타냈다.

#### 4. NN 성능평가

테스트 세트 데이터 120장을 기반으로 한 NN의 오차 행렬은 Table 4와 같다. PA는 30장을 예측하였고, 30장을 PA로 예측하여 100%의 정확도를 나타냈다. Fan lat은 29장을 예측하였고, 29장을 정확히 예측하여 100%로 나타났다. Lat은 30장을 예측하였고, 30장을 정확히 예측하여 100%로 나타났다. Obl은 31장을 예측하였고, 30장은 정확히 예측하였으나 1장을 Fan lat로 예측하여 96.774%의 정확도를 나타냈다.

### IV. 고찰

현행 원자력안전법에 따라 방사선학과 재학생의 경우 일반엑스선검사 실습을 하기 위한 종사자 분류는 원자력안전법 시행령 제2조 제8호에 따라 수시출입자로 분류된다. 이에 따라 실습 교육과정에 있는 방사선학과 학생에 대한 방사선안전관리체계는 작업종사자 수준으로 강화되었다. 방사선학과 대학은 양질의 방사선사 양성을 위한 교육기관으로 교육을 위한 실습을 진행하여야 한다. 그러나 현행 원자력안전법 및 시행령은 교육을 위한 실습을 진행하는 대학 방사선학과에 설치된 방사선발생장치도 안전확보라는 명분으로 방사선안전관리 규정을 적용하고 있다[11]. 방사선안전관리에 대한 지나친 법 적용으로 인하여 일부 대학의 경우 정상적인 실습이 불가피해지는 등 헌법 제31조 제1항에 명시된 학생의 교육을 받을 권리가 침해받고 있으며 이를 해결하기 위한 노력이 필요하다.

기계학습의 경우 사용자가 설정 가능한 하이퍼 파라미터

의 조절을 통하여 성능 향상이 가능하다. 하이퍼 파라미터의 설정은 주어진 데이터의 특성에 따라 다르며 최적 설정을 위하여 시행착오(Trial and error) 방식을 사용하게 된다. 그러나 본 연구에서는 Orange3 에서 제공하는 기본 세팅값을 사용하여 kNN의 이웃의 수는 5, Metric은 Euclidean을 사용하였고, SVM의 Cost는 1.00, RBF 커널을 사용하였다. NN의 경우 Hidden layer는 100, Relu 함수와 Adam optimizer를 사용하였다.

연구는 방사선발생장치를 대신하여 사용 가능한 시뮬레이터 개발을 위한 예비 연구로 오른손 AP, Lat, Fan lat, Obl 사진을 엑스선검사 방향으로 촬영하여 이미지 데이터를 획득하고 다양한 분야의 분류 및 예측에 활용되고 있는 기계학습을 수행한 후 분류 정확도를 평가하여 시뮬레이터로써 활용 가능성 평가에 목적을 두었다[12-15]. 평가 결과 모델별 정확도는 kNN 0.967, SVM 0.992, NN 0.992였으며, AUC는 kNN 0.993, SVM 1.000, NN 0.999로 kNN이 약간 낮았지만 세 모델 모두 높은 정확도와 AUC를 기록하였다.

연구에 적용된 촬영 부위가 간단하게 분류가 가능한 편이기 때문에 3가지 모델 모두 높은 정확도를 기록하였지만 머리와 같이 복잡한 이미지에 적용하였을 때의 정확도는 저하될 수 있다. 또한, 같은 공간에서 정해진 촬영거리 및 자세로 이미지 데이터를 획득하였기 때문에 조명의 밝기 및 배경, 촬영 자세에 따른 영향을 받을 수 있다. 이를 해결하기 위하여 더 많은 이미지 확보를 통한 대규모 데이터 세트의 구성이 필요하며 대규모 데이터 세트를 활용한 데이터 증강(Data augmentation) 기법을 활용한다면 해결 가능할 것으로 생각된다.

### V. 결론

연구에서는 기계학습 분류 모델인 kNN, SVM, NN모델을 사용하여 오른손 PA, Obl, Lat, Fan lat 이미지를 분류

하고 예측하였다. 예측 결과 정확도는 SVM과 NN가 0.992로 같았으며, AUC는 1.000, 0.999로 비슷하게 나타나 두 모델 모두 높은 예측력을 보였고, 교육용 시뮬레이터에 적용 가능성을 알 수 있었다. 이를 통하여 다양한 부위에 대한 적용이 가능해진다면 교육용 시뮬레이터는 일반엑스선검사 실습에 효과적인 학습 도구로 활용될 수 있으며, 학습자의 임상실무역량 강화에 효과적일 것으로 기대된다.

## REFERENCES

- [1] KDCA. Assessment of radiation exposure of Korean population by medical radiation. Korea Disease Control and Prevention Agency; 2020.
- [2] Jeon SM, Lee YK, Ahn SM. A Study on the exposure dose of workers and frequent workers in the radiology department. *Journal of the Korean Society of Radiology*. 2021;15(3):355-9.
- [3] Kang SS, Kim CS, Choi SY, Go SJ, Kim JH. Evaluation of present curriculum for development of dept. of radiological science curriculum. *The Journal of the Korea Contents Association*. 2011; 11(5):242-51.
- [4] Kil JW, Park JH, Kim YG. Study on the planning and operation of training education in radiologic science for reduced x-ray exposure. *Journal of the Institute of Electronics and Information Engineers*. 2014;51(12):174-9.
- [5] Shim JG, Kwon SM. Analysis of learning effect through the development and application of virtual reality(VR) education content for radiology students. *Journal of Radiological Science and Technology*. 2020;43(6):519-24.
- [6] Park HH, Shim JG, Kwon SM. Mixed reality based radiation safety education simulator platform development: Focused on medical field. *Journal of Radiological Science and Technology*. 2021;44(2): 123-31.
- [7] Hong DH. Comparison of CT exposure dose prediction models using machine learning-based body measurement information. *Journal of Radiological Science and Technology*. 2020;43(6):503-9.
- [8] Kwon CM. Python Machine Learning Complete Guide. Gyeonggi: Wikibooks; 2019.
- [9] Park DR, Ahn JM, Jang JH, Yu WJ, Kim WY, Bae YK, et al. The Development of software teaching-learning model based on machine learning platform. *Journal of The Korean Association of Information Education*. 2020;24(1):49-57.
- [10] Kang IW, Sharma R, Jeon SM, Park S, Lee SH, Na YH, et al. Optimized KNN/SVM algorithm for efficient indoor location. *Proceedings of the Korea Information Processing Society Conference*. 2011; 18(2):602-5.
- [11] Lee BW, Kim CG. A Study on the convergence perception of students in radiology on the reorganization of safety management system by person with frequent access of nuclear safety act. *Journal of the Korea Convergence Society*. 2019;10(6):89-94.
- [12] Choi PS, Min IS. A Predictive model for the employment of college graduates using a machine learning approach. *Journal of Vocational Education & Training*. 2018;21(1):31-54.
- [13] Lee GS, Lee JC. A Classification of medical and advertising blogs using machine learning. *Journal of Korea Academia-Industrial cooperation Society*. 2018;19(11):730-7.
- [14] Eom JS, Lee SW, Kim BY. A Feasibility study on the improvement of diagnostic accuracy for energy-selective digital mammography using machine learning. *Journal of Radiological Science and Technology*. 2019;42(1):9-17.
- [15] Lee IJ, Lee JH. Predictive of osteoporosis by tree-based machine learning model in post-menopausal woman. *Journal of Radiological Science and Technology*. 2020;43(6):495-502.

구분	성명	소속	직위
제1저자	이인자	동남보건대학교	교수
공동저자	박채연	동남보건대학교	학생
교신저자	이준호	범부처전주기의료기기연구개발사업단	책임연구원