

&lt;원저&gt;

## 머신러닝을 이용한 에너지 선택적 유방촬영의 진단 정확도 향상에 관한 연구

엄지수<sup>1)</sup>·이승환<sup>1,2)</sup>·김번영<sup>1)</sup><sup>1)</sup>건양대학교 의과학과·<sup>2)</sup>건양대학교 방사선학과

### A Feasibility Study on the Improvement of Diagnostic Accuracy for Energy-selective Digital Mammography using Machine Learning

Jisoo Eom<sup>1)</sup>·Seungwan Lee<sup>1,2)</sup>·Burnyoung Kim<sup>1)</sup><sup>1)</sup>Department of Medical Science, Konyang University<sup>2)</sup>Department of Radiological Science, Konyang University

**Abstract** Although digital mammography is a representative method for breast cancer detection, It has a limitation in detecting and classifying breast tumor due to superimposed structures. Machine learning, which is a part of artificial intelligence fields, is a method for analysing a large amount of data using complex algorithms, recognizing patterns and making prediction. In this study, we proposed a technique to improve the diagnostic accuracy of energy-selective mammography by training data using the machine learning algorithm and using dual-energy measurements. A dual-energy images obtained from a photon-counting detector were used for the input data of machine learning algorithms, and we analyzed the accuracy of predicted tumor thickness for verifying the machine learning algorithms. The results showed that the classification accuracy of tumor thickness was above 95% and was improved with an increase of input data. Therefore, we expect that the diagnostic accuracy of energy-selective mammography can be improved by using machine learning.

**Key Words :** Machine learning, Digital mammography, Dual-energy, Classification, Tumor thickness

**중심 단어 :** 머신러닝, 디지털 유방촬영, 이중에너지, 분류, 종양 두께

## 1. 서 론

한국유방암 학회에서 발표한 자료에 따르면 유방암은 여성의 주요 암 중 2위를 기록하고 있으며, 매년 유방암의 발병률 및 유병률은 계속해서 증가하고 있다[1]. 유방의 치밀도는 유방암 발생과 관련 있으며, 유방이 치밀할수록 유관과 주변 조직을 둘러싸고 있는 세포가 상호작용을 일으키기 때문에 저밀도 유방에 비해 고밀도 유방에서 유방암 발병위험이 약 4-6배 높다. 초산이 시기가 점점 늦어지고, 출산 경

험의 횟수가 적어지는 국내 여성은 외국 여성에 비해 유방의 치밀도가 높으며 이로 인해 매년 유방암 발병률이 높아지고 있다. 또한 같은 인종이라도 연령에 따라 치밀도가 다르며 국내 여성의 경우 특히 30대 및 40대 가장 높은 유방 치밀도를 보인다[1]. 유방암의 진단에는 X선을 이용한 디지털 유방촬영이 대표적이지만 높은 유방 치밀도로 인해 영상에서 종양의 대조도가 낮으며, 유방의 모든 구조물이 중첩되어 나타나기 때문에 종양을 검출하는데 한계가 있다[2]. 이중에너지 유방촬영은 유방을 구성하고 있는 조직의 감약

This research was supported by Basic Science Research Program through the National Research Foundation of Korea (NRF) funded by the Ministry of Science and ICT (Grant No. NRF-2016R1C1B1010642).

Corresponding author: Seungwan Lee, Department of Medical Science, Konyang University, Department of Radiological Science, Konyang University, 158 Gwanjeodong-ro, Seo-gu, Daejeon, 35365, Republic of Korea / E-mail: slee1@konyang.ac.kr

Received 26 November 2018; Revised 27 December 2018; Accepted 27 December 2018

Copyright ©2019 by The Korean Journal of Radiological Science and Technology

계수 차이를 극대화할 수 있는 방법으로 일반적인 단일 에너지 유방촬영에 비해 종양의 대조도를 향상시킬 수 있다. 하지만 두 번의 X선 조사를 기반으로 하기 때문에 환자의 피폭선량이 증가한다는 단점이 있다[3,4]. 광자계수검출기는 일반적인 X선 검출기와는 달리 입사 광자의 에너지를 구별할 수 있으며, CdTe(Cadmium Telluride), CZT(Cadmium Zinc Telluride)와 같이 원자번호가 높은 물질로 구성되어 있기 때문에 검출효율이 높다. 뿐만 아니라 에너지 문턱값 설정을 통해 한번의 X선 조사만으로 에너지 간섭현상이 없는 다중에너지 정보를 획득할 수 있기 때문에 피폭선량 증가 없는 이중에너지 유방촬영이 가능하다[5-9].

현재 의료분야에서 인공지능 및 빅데이터의 활용 가능성에 대한 관심이 증가하고 있다. 인공지능의 한 분야인 머신러닝은 빅데이터 기반의 인공지능 학습방법으로 복잡한 알고리즘을 이용해 대량의 데이터를 분석하고, 패턴을 인식하여 이를 바탕으로 결과를 예측하는 방법이다. 머신러닝은 크게 지도 학습, 비지도 학습, 준지도 학습, 강화 학습으로 나눌 수 있다. 그 중 지도학습의 경우 예측 데이터에 대한 결과 값을 알고 있는 경우에 학습할 수 있는 방법으로, 분류는 전형적인 지도학습 작업이다[10]. 분류를 위한 대표적인 알고리즘에는 LDA(Linear Discriminant Analysis), SVM(Support Vector Machines) 및 KNN(K-Nearest Neighbors) 등이 있다. LDA는 훈련 데이터를 가장 잘 분류할 수 있는 기준선을 찾고, 해당 기준선을 통해 실제 데이터를 분류해주는 알고리즘이다. SVM은 서로 다른 분류에 속한 훈련 데이터간의 간격이 최대가 되는 1차원 또는 2차원 기준벡터를 찾아 이를 기준으로 실제 데이터를 분류하는 알고리즘이다. KNN은 훈련 데이터 중 K개의 가장 가까운 이웃 데이터를 그룹화하고 그 빈도수에 따라 데이터를 분류하는 알고리즘이다[11,12].

본 연구에서는 이중에너지 디지털 유방촬영에서 지도학습 기반 머신러닝을 이용하여 데이터를 학습시킴으로써 에너지 선택적 유방촬영의 진단 정확도를 향상시키고자 하였다. 또한 본 연구에서 제안하는 방법을 일반적인 디지털 유

방촬영영상에서 추출하기 어려운 종양 두께에 대해서 시행하였고, 훈련 데이터 대비 검증 데이터의 비율을 다양하게 설정하여 각 머신러닝 알고리즘을 통해 예측된 종양 두께의 정확도를 비교하였다.

## II. 대상 및 방법

### 1. 몬테카를로 시뮬레이션 및 영상획득조건

본 연구에서는 Gean4 Application for Tomographic Emission(GATE) version 6.0을 이용하여 광자계수검출기 기반 유방촬영 시스템을 모사하였다[13-15]. 초점-검출기간 거리는 600 mm로 설정하였다. 검출기는 eValuator-3500(Kromek, UK)을 기반으로 모델링되었다. eValuator-3500 검출기는 CZT 물질로 구성되어 있으며,  $128 \times 0.5 \times 3 \text{ mm}^3$ 의 크기,  $0.5 \times 0.5 \text{ mm}^2$ 의 픽셀 크기를 갖는다. 또한 5개의 에너지 문턱값을 설정할 수 있기 때문에 에너지 선택적 X선 영상화가 가능하다.

본 연구에서는 4개의 에너지 문턱값을 사용하여 X선 영상을 획득하였다. 본 연구에서 모델링 한 검출기는 선형의 모양을 갖기 때문에 2차원 유방촬영영상을 획득하기 위해 검출기가 일정한 방향으로 이동 가능하도록 시뮬레이션 하였다.

종양 두께추출에 대한 머신러닝의 가능성을 확인하기 위해 펄스중첩과 전하공유는 고려하지 않았다. 압박된 유방을 모사하기 위해 지름 100 mm, 두께 38 mm의 반원 형태의 유방 팬텀을 모델링 하였고, 유방 팬텀을 검출기에 밀착되도록 설정하였다. 유방 팬텀의 물질은 유선조직과 지방질로 구성하였으며, Table 1과 같이 연령에 따라 유선조직과 지방질의 혼합비율을 다르게 하여 30대부터 80대까지 각각 72.15, 70.7, 61.1, 47, 44.55 및 41.65의 유선조직 치밀도를 갖도록 설정하였다[16]. 유방 팬텀 내부에 위치한 종양은 지름 15 mm의 수산화인회석( $\text{Ca}_5(\text{OH})(\text{PO}_4)_3$ )으로 구성하였

**Table 1.** Breast densities and compositions for 30-80s women

Ages	Glandularity	H	C	N	O	P
30	72.15	0.105	0.305	0.028	0.558	0.004
40	70.7	0.105	0.311	0.028	0.552	0.004
50	61.10	0.106	0.353	0.026	0.511	0.003
60	47.00	0.107	0.415	0.024	0.451	0.003
70	44.55	0.108	0.425	0.024	0.441	0.003
80	41.65	0.108	0.438	0.023	0.428	0.003

으며 1-4 mm의 다양한 두께로 설정하였다(Fig. 1)[17].

연속 X선 에너지 스펙트럼은 SRS-78 프로그램을 이용하여 모사되었다[18]. X선 에너지 스펙트럼은 텅스텐 양극, 44 kVp의 관전압, 600  $\mu$ As의 관전류 및 8 mm 알루미늄 필터를 이용하여 0.5 keV 단위로 모사되었다(Fig. 2).

입력 데이터 증가에 따른 머신러닝 정확도 향상을 확인하기 위해 단일 에너지 및 이중 에너지 X-선 영상을 획득하였다. 전체 X-선 에너지 스펙트럼을 이용하여 일반적인 단일 에너지 유방영상을 획득하였으며, 이중 에너지 영상 획득 시 광자계수검출기의 전기적 잡음을 최소화하기 위해 20 keV 이상의 에너지 범위를 선택적으로 설정하여 유방영상을 획득하였다. 또한 유선조직과 종양의 선감약계수를 바탕으로 저에너지 및 고에너지 영상 사이의 종양 대조도 차이를 극대화하기 위해 저에너지 범위를 20-26 keV, 고에너지 범위를 38-44 keV로 설정하여 이중 에너지 유방영상을 획득하였다(Fig. 3).

2. 머신러닝을 이용한 분류기 추출 및 정량적 평가

본 연구에서는 매트랩(MATLAB software version 9.0 (MathWork Inc, USA)) 프로그램 기반 머신러닝을 통한 분류 학습기를 이용하여 종양 두께 추출을 위한 분류기를 생성하였다. 각 에너지 영상에서 6.5 mm의 반지름을 갖는 원형 관심영역을 종양 부위에 설정하여 각 종양 두께에 대한 대조도 대 잡음비를 측정하였다. 대조도 대 잡음비는 다음 식 (1)과 같이 계산할 수 있다[19].

$$CNR = \left| \frac{S_{BKG} - S_{tumor}}{\sqrt{\sigma_{BKG}^2 + \sigma_{tumor}^2}} \right| \dots\dots\dots \text{식 (1)}$$

여기서  $S_{BKG}$  및  $\sigma_{BKG}$ 는 각각 유선조직 신호의 평균값과 표준편차값을 의미하며,  $S_{tumor}$  및  $\sigma_{tumor}$ 는 각각 종양 신호의 평균값과 표준편차를 의미한다. 단일 에너지 및 이중 에너지의 각 에너지 범위에서 측정된 대조도 대 잡음비를 머신러닝의 입력 데이터로, 각 종양의 두께를 머신러닝의 출력 데이터로 이용하여 분류기를 생성하였다. 본 연구에서는 설정된 종양 두께와 X선 영상에서 측정된 대조도 대 잡음비의 관계를 바탕으로 머신러닝을 이용하였기 때문에 동일 종양 두께에 대하여 모든 연령대 X선 영상의 대조도 대 잡음비 수준이 유사할수록, 각기 다른 종양 두께에 대해서는 X선 영상의 대조도 대 잡음비가 중첩되지 않고 분리되어 있을수록 머신러닝의 분류 정확도가 높다는 것을 의미한다.

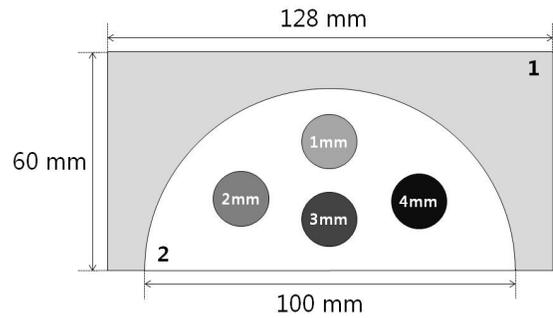


Fig. 1. Schematic illustration of the breast phantom (1 = detector, 2 = breast tissue, Inner cylinders = tumors)

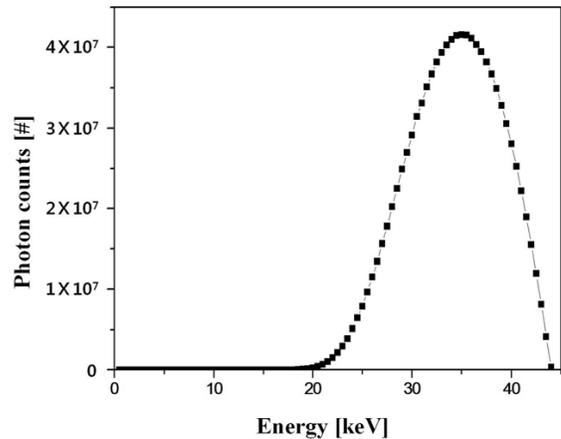


Fig. 2. X-ray energy spectrum simulated by using SRS-78 program

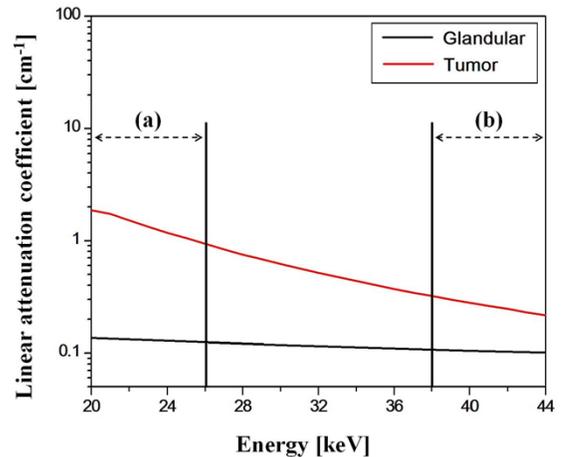


Fig. 3. Linear attenuation coefficient curves as a function of the incident X-ray energy for glandular and tumor. (a) corresponds to the low-energy window of 20-26 keV, and (b) corresponds to the high-energy window of 38-44 keV.

본 연구에서 훈련과 검증 단계로 나누어서 머신러닝 알고리즘의 정확도를 평가하였다. 또한 훈련과 검증 데이터 비

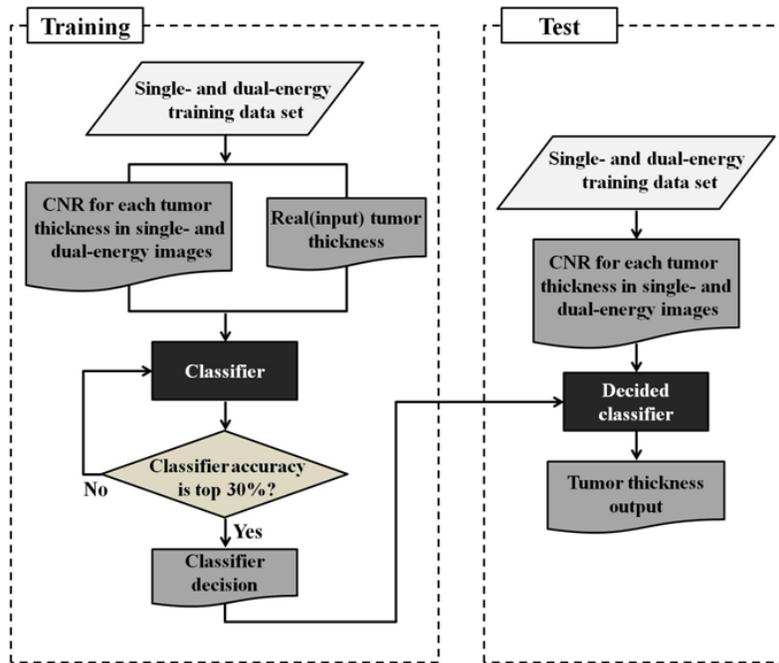


Fig. 4. Training and validation algorithms based on a classifier for extracting tumor thicknesses in single- and dual-energy mammography

율에 따른 정확도 변화정도를 평가하기 위해 훈련 및 검증 데이터의 비율을 2:4, 3:3 및 4:2로 설정하였다. 첫 번째 세트(set 1)는 30대와 40대, 두 번째 세트(set 2)는 30대부터 50대, 세 번째 세트(set 3)는 30대부터 60대까지의 데이터를 훈련 데이터로 이용하였고, 각 세트에서 훈련 데이터에 포함되지 않는 데이터를 검증에 이용하였다. 분류기를 이용한 훈련과 검증 알고리즘은 Fig. 4와 같다.

머신러닝 기반 분류기로 결정 트리(Decision Tree), 판별 분석(Discriminant Analysis), 로지스틱 회귀(Logistic Regression), SVM, KNN 및 앙상블(Ensemble) 알고리즘을 이용하였으며, 각 알고리즘에서 훈련을 통한 분류 기준 설정 시 1-3차의 방정식을 사용하였다. 훈련 정확도는 5-fold cross validation을 이용하여 평가되었다[20]. 전체 분류기 중 훈련 정확도가 상위 30%인 분류기만을 이용하여 검증을 진행하였으며, 각 분류기의 정확도는 식 (2)를 이용하여 계산하였다[21].

$$Accuracy[\%] = \frac{Correct\ predictions}{Total\ predictions} \times 100 \dots\dots\dots \text{식 (2)}$$

여기서 total predictions는 예측된 전체 종양의 개수를 의미하며, correct predictions는 입력한 두께와 동일하게 예측된 종양의 개수를 의미한다.

### III. 결 과

#### 1. 정량적 분석

Fig. 5는 각각 단일 에너지 및 이중 에너지 영상에서 잡음, 종양 두께 및 연령 사이의 상관관계를 보여준다. 단일 에너지 영상의 평균 잡음은 저에너지 및 고에너지 영상보다 각각 약 0.15배 및 0.6배 낮은 결과를 확인하였다. 또한 단일 에너지 및 이중 에너지 영상에서 모든 연령대에 대해 종양의 두께가 증가할수록 잡음이 증가하는 결과를 보여준다.

Fig. 6은 단일 에너지 및 이중 에너지 영상에서 종양의 대조도 대 잡음비, 종양 두께, 연령 사이의 상관관계를 보여준다. 단일 에너지 영상의 평균 대조도 대 잡음비는 저에너지 및 고에너지 영상보다 각각 약 3.4 및 2.1배 높은 결과를 확인하였다. 단일 에너지 영상의 경우, 0 mm 및 1 mm 두께의 종양에 대해서는 상호관계에 의한 분류가 확인되는 반면 나머지 두께의 종양에 대해서는 대조도 대 잡음비의 차이가 작아 분류가 되지 않는 것을 확인할 수 있다. 이는 단일 에너지 유방영상에서는 연령에 관계없이 두꺼운 또는 대조도 대 잡음비가 높은 종양 사이의 구분이 명확하지 않다는 것을 보여주는 결과이다.

반면, Fig. 6(b)에서 확인할 수 있는 바와 같이, 이중 에너지 영상에서는 모든 종양 두께에 대하여 상호관계가 구분될 뿐만 아니라 같은 두께의 종양으로 그룹화 되었다.

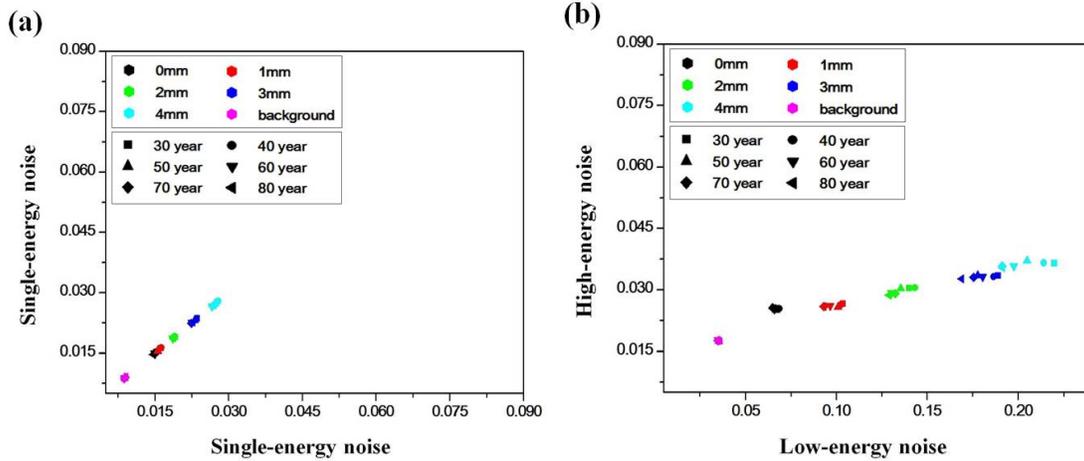


Fig. 5. Relationship between tumor thicknesses, ages, and noises: (a) single-energy mammography, (b) dual-energy mammography

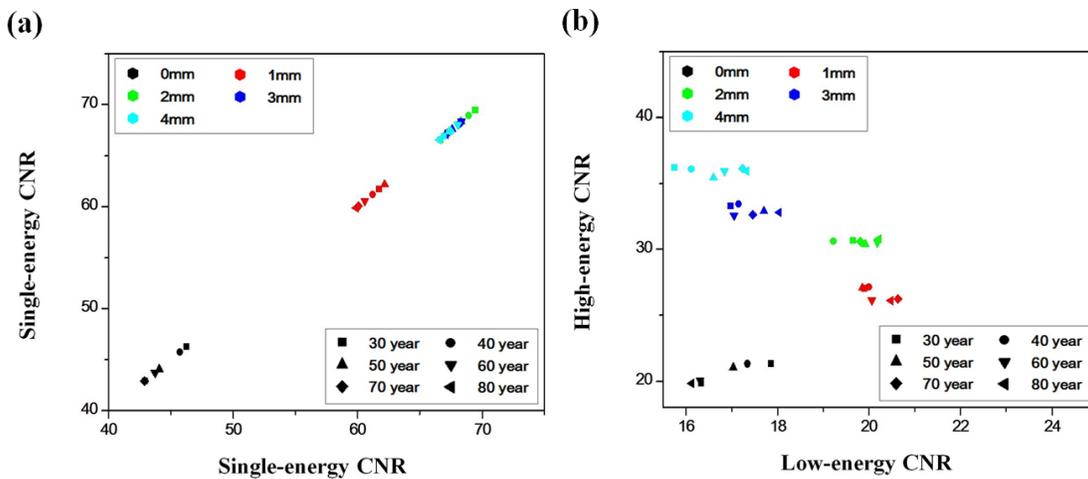


Fig. 6. Relationship between tumor thicknesses, ages, and CNRs: (a) single-energy mammography, (b) dual-energy mammography

## 2. 머신러닝 기반 분류기 정확도

훈련에 사용된 22개의 전체 알고리즘 중 LDA, quadratic SVM, cubic SVM, medium gaussian SVM, fine KNN, weighted KNN 및 ensemble 총 7개의 알고리즘이 높은 훈련 정확도를 보였으며, 해당 알고리즘을 이용하여 검증을 진행하였다. 검증에 사용된 알고리즘의 평균 훈련 정확도는 단일 에너지 및 이중 에너지 영상화 기술에 대해 각각 76% 및 99%를 보였으며, 이중 에너지 기술이 단일 에너지 기술 보다 훈련 정확도가 약 1.3배 높은 것을 확인하였다.

Fig. 7과 Fig. 8은 단일 에너지 및 이중 에너지 영상화 기술을 이용하여 종양 두께 분류 검증에 사용된 각 알고리즘에 대한 평균 정확도, 각 종양 두께 별 평균정확도를 보여준다. 단일 에너지 및 이중 에너지 영상화 기술의 평균 정확도는 각각 60% 및 96%로써 단일 에너지 대비 이중 에너지 영상화 기술의 분류 정확도가 약 1.6배 높은 것을 확인할 수

있었다. 알고리즘별 분류 정확도는 단일 에너지 영상화 기술의 경우 fine KNN 및 weighted KNN 알고리즘에 대해 66%의 가장 높은 정확도를, LAD 및 ensemble 알고리즘에 대해 56%의 가장 낮은 정확도를 보였다. 이중 에너지 영상화 기술의 경우 LAD 및 ensemble 알고리즘에 대해 100%의 가장 높은 정확도를, quadratic SVM 및 cubic SVM에 대해 93%의 가장 낮은 정확도를 보였다.

각 종양 두께 별 분류 정확도는 단일 에너지 영상화 기술의 경우 0 mm와 1 mm 종양에 대해 100% 분류 정확도를, 2 mm, 3 mm, 4 mm 종양에 대해 각각 12%, 37%, 50% 정확도를 보였다. 반면, 이중 에너지 영상화 기술의 경우 0 mm, 1 mm, 2 mm 및 3 mm 종양에 대해 100% 분류 정확도를, 4 mm 종양에 대해 79% 분류 정확도를 보였다.

훈련 및 검증 데이터 비율에 따른 평균 분류 정확도는 단일 에너지 영상화 기술의 경우 set 1, set 2 및 set 3에서

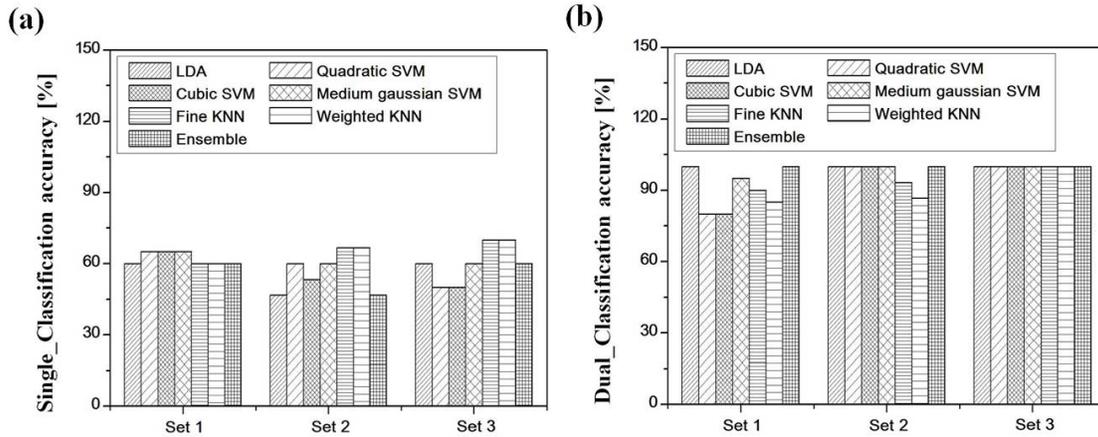


Fig. 7, Classification accuracy using each machine learning algorithm. (Ratio between training- and test set, set1 = 2:4, set 2 = 3:3, set 3 = 4:2)

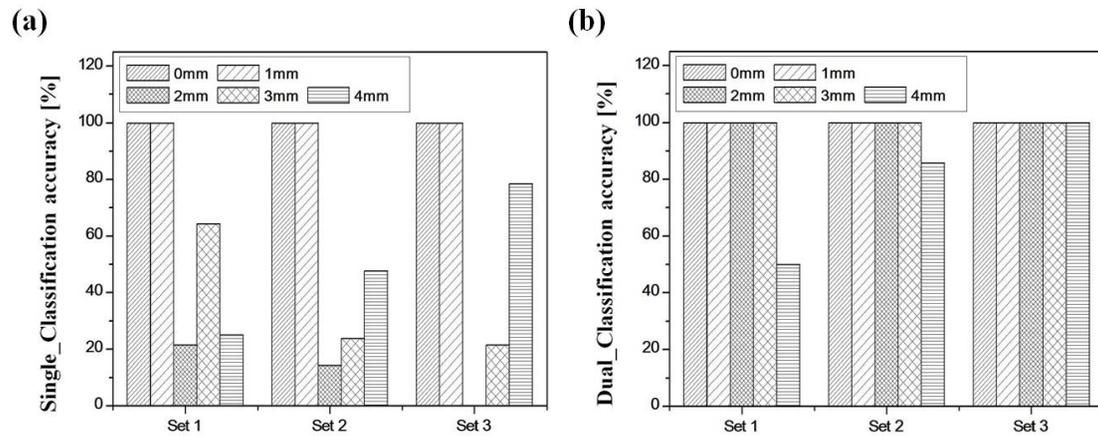


Fig. 8, Classification accuracy for each tumor thickness. (Ratio between training- and test set, set1 = 2:4, set 2 = 3:3, set 3 = 4:2)

각각 74.5%, 66% 및 65%의 정확도를 보임으로써 데이터 비율에 따른 분류 정확도 향상 효과는 확인할 수 없었다. 반면, 이중 에너지 영상화 기술의 경우 set 1, set 2 및 set 3 에서 각각 95%, 97.5% 및 100%의 정확도를 확인하였다. 이와 같은 결과는 동일한 데이터 조건에서 단일 에너지 영상화 기술에 비해 이중 에너지 영상화 기술이 분류의 정확도를 향상시킬 수 있다는 것을 나타낸다. 또한 이중 에너지 영상화 기술의 경우 훈련 데이터의 양이 증가할수록 분류 정확도는 향상된다는 것을 보여준다.

#### IV. 고 찰

본 연구에서는 광자계수검출기 기반 이중 에너지 스펙트럼 유방촬영에서 머신러닝 기술을 이용한 종양 검출 및 분류 가능성을 확인하고자 하였다. 또한 분류 정확도 평가를

통해 일반적인 단일 에너지 유방촬영 기법과의 비교를 진행하였다.

광자계수검출기를 이용하여 한 번의 X선 조사를 통해 방사선량의 증가 없이 이중 에너지 영상화 기법 구현이 가능함을 확인하였다. 영상화질의 정량적 분석 결과, 단일 에너지 영상화 기술에 비해 이중 에너지 영상화 기술을 통해 획득한 영상의 잡음 및 대조도 대 잡음비 특성이 저하되는 것을 확인하였다. 이는 이중 에너지 영상화 기술 구현 시 입사되는 X선 에너지에 대한 물질의 감약 차이를 최대화하기 위해 일부 에너지 범위를 선택적으로 사용하였기 때문이다. 이와 같은 선택적 에너지 사용은 영상 구현에 이용되는 유효광자수를 감소시키고, 영상에서 통계적 잡음을 증가시키는 효과로 이어진다. 그림 3에서 확인할 수 있듯이 유방조직과 종양의 선감약계수 차이는 고에너지 영역보다 저에너지 영역에서 상대적으로 크에도 불구하고, 대조도 대 잡음비는 오히려 저에너지 영역에서 획득한 영상보다 고에너지

영역에서 약 1.6배 높은 것을 볼 수 있다(Fig. 6(b)). 이와 같은 결과는 Fig. 5(b)에서 확인할 수 있듯이 저에너지 영역에서 획득한 영상의 잡음 수준이 고에너지 영역에서 획득한 영상보다 약 4배 크기 때문이다. 즉, 광자계수검출기 기반 이중 에너지 기술을 통해 획득한 영상은 잡음에 민감하며, 본 연구와 같이 머신러닝 기술을 이용하여 종양 검출 가능성 및 분류 정확도를 더욱 향상시키기 위하여 denoising 처리와 같은 추가적인 영상처리가 필요하다[22]. 잡음 특성 개선에 따른 종양 검출 정확도 결과는 추후 연구에서 다룰 예정이다.

머신러닝 기반 종양 분류 결과, 그림 7에서 볼 수 있듯이 모든 알고리즘에서 단일 에너지 기술에 비해 이중 에너지 기술의 정확도가 높았다. 단일 에너지 기술의 경우 Fig. 6(a)에서 확인할 수 있듯이 0 mm 와 1 mm 종양의 대조도 대 잡음비는 타 종양과의 분리 정도가 크지만 2 mm, 3 mm 및 4 mm 종양의 대조도 대 잡음비는 서로 매우 유사하다. 이와 같은 결과는 Fig. 8(a)에서 확인할 수 있듯이 종양 검출 및 분류 정확도 저하로 이어진다. 반면에 이중 에너지 기술의 경우 Fig. 6(b) 및 Fig. 8(b)에서 확인할 수 있듯이 각 종양의 대조도 대 잡음비 차이를 극대화할 수 있을 뿐만 아니라 그에 따른 종양 검출 및 분류 정확도를 향상시킬 수 있다.

훈련 및 검증 데이터 비율에 따른 결과에서 단일 에너지 기술의 경우 훈련 데이터 증가와 종양 분류 정확도 사이의 상관관계를 확인할 수 없었지만, 이중 에너지 기술의 경우 훈련 데이터가 증가함에 따라 종양 분류 정확도가 향상되며 set 3의 경우 모든 알고리즘에서 100% 분류 정확도를 확인하였다. 이와 같은 결과는 머신러닝을 이용한 광자계수검출기 기반 유방촬영에서 알고리즘 훈련 데이터의 양을 증가시킬수록 종양 검출 및 분류 가능성을 높일 수 있다는 것을 보여준다.

Kourou K et al.가 제시한 암 예측을 위한 머신러닝 연구의 경우 암의 유무만을 확인하기 때문에 종양의 두께를 추출하는 데에는 한계점이 있으며, 최저 68%, 최고 100% 및 평균 82%의 정확도로 암의 유무를 예측 및 분류함으로써 최저 95%, 최고 100% 및 평균 97.5%의 분류 정확도를 보이는 본 연구에서 제시한 이중에너지 기반 머신러닝보다 낮은 분류 정확도를 보이는 것을 알 수 있다[23]. 뿐만 아니라 본 연구에서 제시한 방법의 경우 0 cm 종양 두께를 통해 종양의 유무를 알 수 있을 뿐만 아니라 다양한 종양의 두께를 분류할 수 있음을 알 수 있다.

본 연구에서는 머신러닝을 이용한 에너지 선택적 유방촬영의 진단 정확도 향상 가능성을 확인하는 것에 중점을 두

고 있기 때문에 광자계수검출기의 단점인 펄스중첩과 전하 공유는 고려하지 않았다. 펄스중첩과 전하공유는 검출기에서 측정되는 X선 에너지 스펙트럼의 정확도를 감소시키기 때문에 본 연구결과에 대조도 감소 및 잡음 증가와 같은 영향을 미칠 수 있을 것이다. 하지만 이 두 현상은 분석적 모델 및 pixel binning을 통해 보정 가능하며, 추후 연구에 적용하여 본 연구에서 제안하는 방법의 신뢰성을 더욱 향상시킬 것이다[24]. 본 연구의 경우 유방 팬텀을 이용한 시뮬레이션 결과이며, 동일한 유방 두께를 기반으로 연령별로 대표적인 치밀도를 이용하여 팬텀을 모사하였기 때문에 동일한 연령대라도 다양한 두께 및 치밀도를 가지는 실제 임상 데이터 적용 시 결과 값의 양상이 다르게 나타날 수 있다. 또한 1 mm 간격으로 종양의 두께를 분류하였기 때문에 1 mm 이하의 두께 차이를 보이는 종양에 대해서는 분류 정확도가 상이할 것이다. 따라서 더욱 다양한 유방 두께 및 치밀도를 고려하고, 종양 두께의 분류 간격을 세밀화하여 분류기를 추출한다면 더욱 향상된 분류 및 진단 정확도를 보일 것으로 사료된다. 뿐만 아니라 유방 치밀도의 조합을 다양하게 설정하여 머신러닝 알고리즘 훈련 시 적용한다면 종양 검출 및 분류 정확도를 더욱 향상시킬 수 있을 것이라 생각된다.

## V. 결 론

국내 여성의 높은 유방 치밀도와 유방암의 증가 추세, 구조물의 중첩과 같은 디지털 유방영상의 한계점을 고려하였을 때 유방암의 진단 정확도 향상은 중요하다. 의료분야에서 인공지능의 활용을 통해 의료영상 화질 및 진단 정확도 향상을 기대할 수 있다.

본 연구에서는 유방 팬텀을 이용하여 광자계수검출기 기반 이중에너지 디지털 유방촬영에서 종양 두께 추출을 위한 머신러닝 입력데이터를 증가시켜 평균 95% 이상의 분류 정확도를 확인하였다. 일반적인 유방촬영에서 불가능한 종양 두께를 추출할 수 있는 방법을 제안하였으며, 추가적인 검사 없이 실제 종양과 근사한 두께로 종양을 분류할 수 있는데 의의가 있다.

에너지 선택적 유방촬영에서 종양 두께 추출을 위한 머신러닝 기술은 진단 대상의 연령에 국한되지 않고 유방촬영 기술 개발 및 인공지능 기반 의료영상 진단 정확도 향상을 위한 기초자료로 활용될 수 있으며, 유방암 조기 발견에 일조할 수 있을 것이다.

## REFERENCES

- [1] Korean Breast Cancer. Breast Cancer Facts & Figures 2018, Seoul: Korean Breast Cancer Society; 2018.
- [2] Wu T, Stewart A, Stanton M, McCauley T, Phillips W, Kopans DB, et al. Tomographic Mammography using a Limited Number of Low-dose Cone-beam Projection Images. *Medical Physics*. 2003;30(3): 365–80.
- [3] Leschka S, Stolzmann P, Schmid FT, Scheffel H, Stinn B, Marincek B, et al. Low Kilovoltage Cardiac Dual-source CT: Attenuation, Noise, and Radiation Dose. *European Radiology*. 2008;18(9):1809–17.
- [4] Lewin JM, Isaacs PK, Vance V, Larke FJ. Dual-energy Contrast-enhanced Digital Subtraction Mammography: Feasibility. *Radiology*. 2003;229(1): 261–8.
- [5] Takahashi T, Watanabe S. Recent Progress in CdTe and CdZnTe Detectors. *IEEE Transactions on Nuclear Science*. 2001;48(4):950–9.
- [6] Laidevant AD, Malkov S, Flowers CI, Kerlikowske, Shepherd JA. Compositional Breast Imaging using a Dual-energy Mammography Protocol. *Medical Physics*. 2010;37(1):164–74.
- [7] Choi Y, Cho H, Lee S, Ryu H, Lee Y. Material Decomposition in Contrast-enhanced Digital Mammography based on Photon Counting: Monte Carlo Simulation Studies. *Korean Physical Society*. 2011;59(1):161–8.
- [8] Miyajima S, Imagawa K. CdZnTe detector in Mammographic X-ray Spectroscopy. *Physics in Medicine and Biology*. 2002;47(22):3959.
- [9] Barber WC, Nygard E, Iwanczyk JS, Zhang M, Frey EC, Tsui BMW, et al. Characterization of a Novel Photon Counting Detector for Clinical CT: Count Rate, Energy Resolution, and Noise Performance. In *Medical Imaging 2009: Physics of Medical Imaging*. 2009;7258:725824.
- [10] Géron A. *Hands-on Machine Learning with Scikit-learn & Tensorflow*. Korea: Hanbit Media Inc; 2016.
- [11] Subasi A, Gursoy MI. EEG Signal Classification using PCA, ICA, LDA and Support Vector Machines. *Expert Systems with Applications*. 2010;37(12): 8659–66.
- [12] Zhang H, Berg AC, Marie M, Malik J. SVM-KNN: Discriminative Nearest Neighbor Classification for Visual Category Recognition. In *Computer Vision and Pattern Recognition*. In *Computer Vision and Pattern Recognition*, 2006 IEEE Computer Society Conference on. 2006;2:2126–36.
- [13] Jan S, Benoit D, Becheva E, Cassol F, Descourt P, Frisson T, et al. GATE V6: a Major Enhancement of the GATE Simulation Platform Enabling Modelling of CT and Radiotherapy. *Physics in Medicine and Biology*. 2011;56(4):881.
- [14] Lee C. Estimation of Computed Tomography Dose in Various Phantom Shapes and Compositions. *Journal of Radiological Science and Technology*. 2017;40(1):13–8.
- [15] An S, Lee C, Baek C. Monte Carlo Simulation of a Varian 21EX Clinac 6 MV Photon Beam Characteristics Using GATE6. *Journal of Radiological Science and Technology*. 2016;39(4):571–5.
- [16] Youn I, Choi S, Kook S, Choi Y. Mammographic Breast Density Evaluation in Korean Women using fully Automated Volumetric Assessment. *Journal of Korean Medical Science*. 2016;31(3):457–62.
- [17] Castronovo A, Bellahcene A. Evidence that Breast Cancer Associated Microcalcifications are Mineralized Malignant Cell. *International Journal of Oncology*. 1998;12(2):305–13.
- [18] Carney K, Gilmore BJ, Fogarty GWA, Desponds L. *Catalogue of Diagnostic X-ray Spectra and Other Data: Report No 78*. Institute of Physics and Engineering in Medicine; 1997.
- [19] Desai N, Singh A, Valentino DJ. Practical Evaluation of Image Quality in Computed Radiographic (CR) Imaging Systems. In *Medical Imaging 2010: Physics of Medical Imaging*. International Society for Optic and Photonics. 2010;7622:76224Q.
- [20] Bengio Y, Grandvalet Y. No Unbiased Estimator of the Variance of K-fold Cross Validation. *Journal of Machine Learning Research*. 2004;5:1089–105.

- [21] Stehman SV. Selecting and Interpreting Measures of Thematic Classification Accuracy. Remote Sensing of Environment. 1997;62(1):77-89.
- [22] Buades A, Coll B, Morel JM. A Non-local Algorithm for Image Denoising, Ciboyer Vision and PAttern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on. 2005;2:60-5.
- [23] Kourou K, Exarchos TP, Exarchos KP. Machine Learning Applications in Cancer Prognosis and Prediction. Computational and Structural Biotechnology Journal. 2015;13:8-17.
- [24] Taguchi K, Iwaczyk JS. version 20/20: Single Photon counting X-ray Detectors in Medical Imaging. Medical Physics. 2013;40(10):100901.