

Image Classification of Thyroid Ultrasound Nodules using Machine Learning and GLCM

Ye-Na Jung, Soo-Young Ye*

Department of Radiological Science, College of Health Sciences, Catholic University of Pusan

Received: July 01, 2024. Revised: August 14, 2024. Accepted: August 31, 2024.

ABSTRACT

This study aimed to classify normal and nodule images in thyroid ultrasound images using GLCM and machine learning. The research was conducted on 600 patients who visited S Hospital in Busan and were diagnosed with thyroid nodules using thyroid ultrasound. In the thyroid ultrasound images, the ROI was set to a size of 50x50 pixels, and 21 parameters and 4 angles were used with GLCM to analyze the normal thyroid patterns and thyroid nodule patterns. The analyzed data was used to distinguish between normal and nodule diagnostic results using the SVM model and KNN model in MATLAB. As a result, the accuracy of the thyroid nodule classification rate was 94% for SVM model and 91% for the KNN model. Both models showed an accuracy of over 90%, indicating that the classification rate is excellent when using machine learning for the classification of normal thyroid and thyroid nodules. In the ROC curve, the ROC curve for the SVM model was generally higher compared to the KNN model, indicating that the SVM model has higher within-sample performance than the KNN model. Based on these results, the SVM model showed high accuracy in diagnosing thyroid nodules. This result can be used as basic data for future research as an auxiliary tool for medical diagnosis and is expected to contribute to the qualitative improvement of medical services through machine learning technology.

Keywords: Ultrasound of Thyroid nodule, GLCM, Machine Learning, SVM, KNN

I. INTRODUCTION

갑상샘 결절(Thyroid nodule)은 비교적 흔하게 발생하는 질병으로, 촉진되는 갑상샘 결절은 전체 인구의 약 5%정도에서 발견되며, 비촉진 결절은 40~50%에 이르는 것으로 알려져 있다^[1,2]. 무작위로 선택된 성인의 60% 이상에서 갑상샘 결절이 확인될 정도로 매우 흔하지만, 갑상샘 결절의 5~15%만이 갑상샘 암으로 판명된다^[3]. 갑상샘 결절은 촉진 또는 초음파 검사로 주변의 정상 갑상샘 조직과 경계가 명확하게 구별되는 병변이다. 갑상샘 결절은 악성 여부와 상관없이 결절의 크기가 커질 경우 기도나 주위 조직을 눌러서 증상을 일으키기도 한다^[4].

갑상샘 결절의 발견은 고해상도 초음파 기기의

이용량이 증가함에 따라 갑상샘 결절 유병률은 성인의 30~40%에서 우연히 발견될 정도로 높아졌다^[5]. 초음파를 이용해 갑상샘 결절을 진단할 때, 결절의 크기뿐만 아니라 저에코, 미세석회화 등의 초음파 특성을 통해 악성 결절을 시사할 수 있어 암의 가능성을 예측하는 데 도움을 준다^[6].

초음파 검사는 실시간 검사의 장점에도 불구하고 판독 결과에서 많은 차이를 보이기 때문에 그 중요성에도 불구하고 집단검사 등에서 표준적이고 객관적인 검사 방법으로 인정받지 못하고 있다. 또한, 의사 또는 방사선사가 직접 초음파 검사를 하면서 병변의 유무를 확인해야 하므로 환자 수가 많은 종합병원 등에서는 의사와 방사선사의 피로도 증가로 인한 오진 발생률이 높아질 수 있다. 초음파 영상의 판독은 주관적이어서 같은 영상에 대한

* Corresponding Author: Soo-Young Ye

E-mail: syye@cup.ac.kr

Tel: +82-51-510-0586

판독이 검사자마다 다를 수 있다는 단점도 있다. 갑상샘 초음파 검사에 의한 암 진단은 초음파 영상상의 병변의 특징을 판독하여 양성이나 악성으로 분류하는 방식으로 이루어진다. 그러나 숙련되지 못한 의사와 방사선사는 병변을 찾아내고 이를 분류하는 데 어려움을 겪을 수 있다^[7].

국외의 경우 Vadhiraj 등에 의해 GLCM(Gray Level Co-occurrence Matrix) 영상 분석과 머신러닝(Machine Learning)의 ANN(Artificial Neural Network) 모델과 SVM(Support Vector Machine) 모델을 이용한 초음파 영상의 갑상샘 결절의 영상 분석에 대한 연구가 진행되었다^[8]. 이에 본 연구는 갑상샘 초음파 영상을 이용한 갑상샘 결절 자동 판독 프로그램을 개발하여 갑상샘 소견을 분류하고자 한다. 갑상샘 결절 패턴을 회색조(Gray)영상을 대상으로 영역을 구성하는 각 화소(pixel)의 명암을 이용하여 이웃한 화소가 가진 명암과의 관계에 대한 발생하는 빈도수를 나타낸 행렬을 이용한 GLCM^[9]으로 갑상샘 질감(texture)을 분석하고, 머신러닝의 KNN(K-Nearest Neighborhood) 모델과 SVM 모델을 이용하여 진단 결과가 갑상샘 양성과 갑상샘 결절을 자동으로 분류하여 진단에 도움을 주고자 한다.

II. MATERIAL AND METHODS

1. 연구대상

2021년 1월 1일부터 2023년 12월 31일까지 부산 소재 시 S병원에서 갑상샘 초음파 검사를 받은 수검자 중 갑상샘 결절이 진단된 수검자를 연구 대상으로 선정하였다.


갑상샘 초음파 판독은 영상의학과 전문의가 수행하였으며 정상 200증례와 결절 400증례, 총 600증례의 갑상샘 초음파 영상을 연구 데이터로 준비하였다.

2. 연구 방법

2.1. 갑상샘 초음파 검사

본 연구에서 사용된 초음파 영상의료기는 LOGIQ P9, GE Medical Systems, Korea 장비로 10~15 MHz 직선 탐촉자를 이용하여 연구를 진행하였다.

갑상샘 초음파 검사는 영상의학과 전문의가 판독하였다. 영상의학과 전문의 판독 결과와 대한갑상선영상의학회에서 갑상샘 결절 분류를 제시한 K-TIRADS^[4] 방법으로 정상 갑상샘은 카테고리 1,2를 포함하였고, 갑상샘 결절은 카테고리 3,4를 포함하였다. Fig 1과 같이 분류하였다.

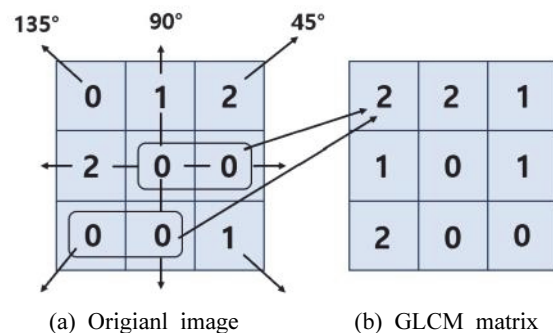


(a) Thyroid Normal (b) Thyroid Nodule

Fig. 1. Ultrasonographic Image.

2.2. GLCM (Gray Level Co-occurrence Matrix)

GLCM은 분석 대상 영상의 공간적 특성을 강조하여 영상의 특징을 추출하는 파라미터(parameter)를 결정하는데 사용된다. 공간적 특성을 나타내기 위해 현재 화소와 이웃 화소의 밝기 값 간의 관계를 바탕으로 대비, 상관관계, 대조 등 통계적 값을 계산한다. 계산된 값들은 커널의 중심 화소에 새로운 밝기 값으로 나타내어 관심 영역의 부분적인 질감 특징을 표현하는 기법이다.



(a) Original image (b) GLCM matrix

Fig. 2. Direction setting of the neighbor pixel.

화소간의 연관성을 파악하기 위하여 Fig. 2와 같이 필요한 연산 방향을 결정하고, 연산된 방향으로 동시에 존재하는 발생 빈도 값을 행렬 방식으로 표현한다.

즉, (a)의 영상의 가로 방향에서 0,0에 해당하는 횡수가 두 번 나타나며, 이 값을 GLCM 매트릭스의 (0,0)좌표에 2로 기록하여 새로운 매트릭스를 만든다. GLCM은 특정 방향의 인접한 화소 사이의 밝기 값 차이의 빈도를 나타내며, 이는 화소의 위치와는 무관한 특징을 가진다. 이러한 특징은 영상 분석에 유리하며, 특징값을 사용함으로써 2차원 영상을 화소 단위로 비교하는 것보다 빠르게 비교 분석할 수 있다^[10,11,12,13].

본 연구에서는 갑상샘 초음파 영상에서 관심영역 (ROI, Region of Interest)를 설정하고, 50×50 화소 크기로 이미지를 획득하여 MATLAB 2023b (MathWorks Inc. USA)를 이용하여 Table 1과 같이 GLCM 특징 21개의 파라미터와 4가지 각도(0°, 45°, 90°, 135°)로 Fig. 3과 같이 갑상샘의 정상패턴과 결절패턴의 질감을 분석하였다.

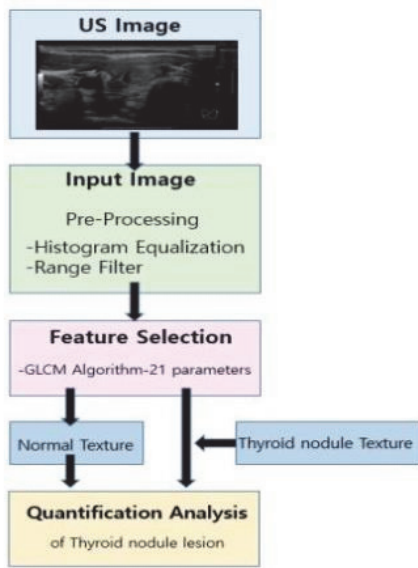


Fig. 3. Diagram of GLCM algorithm.

2.3. KNN (K-Nearest Neighborhood)

KNN(K-Nearest Neighborhood)은 미리 정의되어 있는 클래스에 기초하여 표본을 분류하는 지도학습의 일종으로써 데이터들의 클래스에서 확률분포에 관한 사전정보 없이도 알려진 클래스 구성원들을 지닌 데이터 표본(sample)들을 토대로 분류가 이루어지는 비모수적(non-parametric) 기법의 대표적 분류 알고리즘이다.

Table 1. Parameters of GLCM algorithm

Parameters	Equation
Autocorrelation	$= \sum_{i,j} \frac{(i-\mu_i)(j-\mu_j)}{\sigma_i \sigma_j}$
Contrast	$= \sum_{i,j} i-j^2 P(i,j)$
Correlation : corr _m	$= \sum_{i=1}^N \sum_{j=1}^N \left(\frac{i-\mu_x}{\sigma_x} \right) \left(\frac{j-\mu_y}{\sigma_y} \right) p(i,j)$
Correlation : corr _p	$= \sum_{i=1}^N \sum_{j=1}^N \left(\frac{i-\mu_x}{N} \right) \left(\frac{j-\mu_y}{N} \right) p(i,j) \Delta_{ij}$
Cluster prominence	$= \sum_{i,j} i+j-\mu_x-\mu_y^4 \cdot P(i,j) y$
Cluster shade	$= \sum_{i=1}^N \sum_{j=1}^N (i+j-2\mu)^4 p(i,j)$
Dissimilarity	$= \sum_{i=1}^N \sum_{j=1}^N i-j \cdot p(i,j)$
Energy	$= \sum_{i=1}^N \sum_{j=1}^N p(i,j)^2$
Entropy	$= \sum_{i,j} P(i,j) * \log(P(i,j))$
Homogeneity	$= \sum_{i=1}^N \sum_{j=1}^N \frac{p(i,j)}{1+(i-j)^2}$
Maximum probability	$= \text{Max}(P)$
Sum of squares : Variance	$= \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} (i-\mu)^2 P_d, \theta(i,j)$
Sum average	$= \sum_{i=0}^{2G-2} i P_{x+y}(i)$
Sum variance	$= \sum_{i=0}^{2(N_g-1)} (i-f_7)^2 p_{x+y}(i)$
Sum entropy	$= - \sum_{i=0}^{2(N_g-1)} p_{x+y}(i) \log p_{x+y}(i)$
Difference variance	$= \sum_{i=0}^{N_g-1} (i-f'_{10})^2 p_{x-y}(i)$
Difference entropy	$= - \sum_{i=0}^{N_g-1} p_{x-y}(i) \log p_{x-y}(i)$
Information measure of correlation 1	$= \frac{HXY - HXY_1}{\max(HX, HY)}$
Information measure of correlation 2	$= (1 - \exp[-2(HXY_2 - HXY)])^{1/2}$
Inverse difference normalized	$= \sum_{i=1}^N \sum_{j=1}^N \frac{p(i,j)}{1+ i-j }$
Inverse difference moment normalized	$= \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \frac{1}{1+(i-j)^2} p_d, \theta(i,j)$

즉, KNN은 분류하고자 하는 클래스의 종류에 대해 알고 있지만 표본 각각에 대한 확률밀도함수를 알지 못할 때 사용한다. 여기서 표본의 값을 그대로 좌표에 표시한 후 참조 세트에서 가장 유사하거나 거리상으로 가까운 클래스로 분류한다. 여기서 ‘가깝다’는 뜻은 유클리디안 거리(Euclidean distance), 절대차(Absolute difference), 또는 최대 거리(Maximum distance) 등의 측정치 기준으로 정의된다. 즉, 새로 입력된 표본에서 가까운 k개의 이웃점을 살펴봐야 많은 수의 이웃점이 속한 클래스로 분류하는 방식이다.

아래 Fig. 4의 예와 같이, k=1인 경우에는 가장 가까운 이웃이 속해 있는 △클래스로 분류되고, k=3인 경우에는 k개의 가까운 이웃이 속해 클래스 중 다수 클래스인 □클래스로 분류된다. k는 홀수를 사용하는 것이 일반적이며 본 연구에서는 k=3을 사용하였다^[14,15].

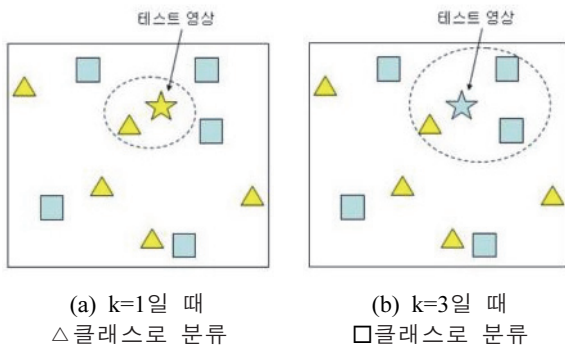


Fig. 4. Rule of KNN.

2.4. SVM (Support Vector Machine)

SVM(Support Vector Machine)의 기본 원리는 훈련데이터(training set)들을 서로 다른 두 집단으로 분류할 때 기준이 되는 분류경계(hyperplane)를 찾는 것이다. 즉, SVM의 목적은 학습 자료로 주어진 n차원의 벡터 공간에서 분류공간 간에 모든 점들 사이의 거리를 최대화하도록 만드는 최대여백 분류경계(maximal margin hyperplane)를 구하는 것이다. 아울러 최대 여백 분류 경계에 가장 가까운 점들을 support vector라고 부른다.

SVM이 주목받는 이유는 첫째, 명백한 근거에 기반하므로 결과 해석이 용이하고, 둘째, 인공지능

분야의 실제 응용에 있어서 우수한 성과를 내고, 셋째, 적은 학습 자료만으로 신속하게 분류학습(classification learning)을 수행 할 수 있기 때문이다.

SVM은 기본적으로 직선으로 분리 할 수 있는 문제에서 적용할 수 있다. 두 집단이 1 또는 -1로서 분류된다고 하면 최적 분류 경계를 기준으로 Eq. (1)과 Eq. (2)의 조건을 만족해야 한다.

$$W \cdot X + b \geq 1 \text{ If 집단} = 1 \tag{1}$$

$$W \cdot X + b + 1 \leq -1 \text{ If 집단} = -1 \tag{2}$$

여기서 X는 임의의 점이며 이 조건식은 Eq. (3)과 같이 통합된 조건식으로 표현될 수 있다.

$$(1 \text{ 또는 } -1)(W \cdot X + b) \geq -1, i=1,2,\dots,N \tag{3}$$

결론적으로 Fig. 5와 같이 두 집단의 데이터를 최적 분류 경계선에 의하여 최종적으로 분류할 수 있다.

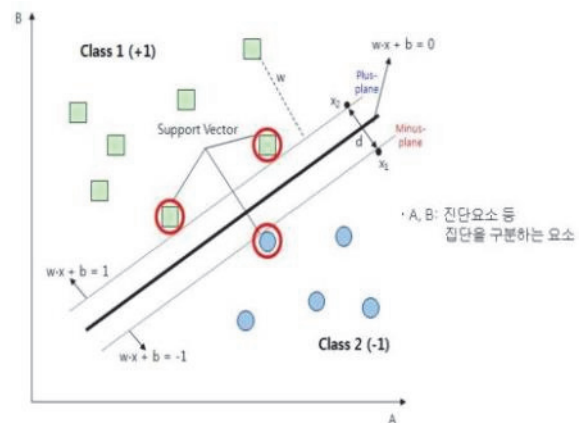


Fig. 5. Border of SVM.

즉, plus plane이 $W \cdot X + b = 1$ 이고, minus plane이 $W \cdot X + b = -1$ 이면, minus plane - plus plane은 $W \cdot (X_1 - X_2) = 2$ 가 된다. 이때 최적 분류 경계선과 각 그룹의 가장 근접한 데이터를 support vector라고 한다. SVM의 선형 의사 결정의 목적 함수는 각 그룹

의 support vector 거리 즉, $d=2/\|W\|$ 를 최대화 하는 것이다^[16,17].

2.5. 실험방법

본 연구에서는 부산 소재지 S병원에서 수집한 600개의 갑상샘 영상에서 관심 영역(ROI)를 설정하고, 50×50 화소 크기로 이미지를 획득하여 MATLAB 2023b(MathWorks Inc. USA)를 이용하여 특징 21개의 파라미터와 4가지 각도(0°, 45°, 90°, 135°)로 Fig. 3과 같이 갑상샘의 정상 패턴과 결절 패턴의 질감을 GLCM으로 분석하였다.

GLCM으로 분석된 데이터를 학습영상과 테스트 영상 두 가지로 나누었다. 분석된 자료 600개의 데이터 중 테스트데이터로 영상 420중례(정상:140, 결절:280)를 사용하였고, 학습데이터로 180중례(양성:60, 결절:120)를 사용하였다. 머신러닝 모델 중 KNN모델과 SVM모델을 사용하여 실험을 진행하였다.

III. RESULT

1. SVM을 이용한 갑상샘 결절 분류 결과

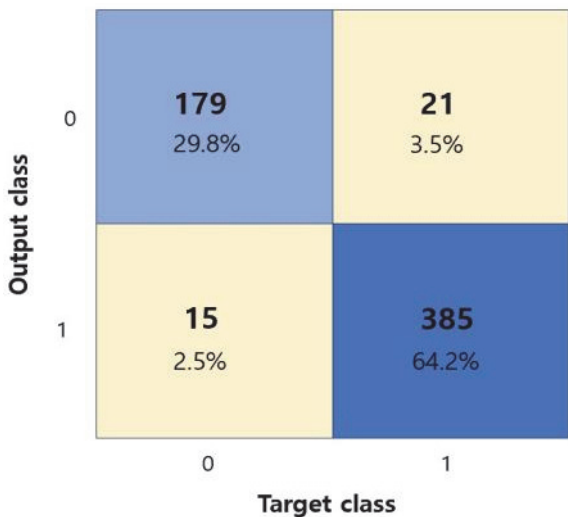


Fig. 6. Result of using SVM model confusion matrix.

Fig. 6에서 처음 2개의 대각선 셀에는 훈련된 모델이 올바르게 분류한 개수와 비율이 표시되어 있다. 179건의 데이터가 양성으로 올바르게 분류되었다. 이는 총 600건의 데이터 중 29.8%에 해당한다. 마찬가지로, 데이터 385건이 악성으로 올바르게 분

류되었다. 전체 데이터의 64.2%에 해당한다.

악성으로 분류된 데이터 결과 중 21건이 양성으로 잘못 분류되었으며, 이는 데이터에 있는 총 600건의 데이터 검사 중 3.5%에 해당한다. 마찬가지로, 양성으로 분류된 데이터 중 15건이 악성으로 잘못 분류되었는데, 이는 모든 데이터의 2.5%에 해당한다.

2. KNN을 이용한 갑상샘 결절 분류 결과



Fig. 7. Result of using KNN model confusion matrix.

Fig. 7에서 180건의 데이터가 양성으로 올바르게 분류되었다. 이는 총 600건의 데이터 중 30%에 해당한다. 마찬가지로, 데이터 61건이 악성으로 올바르게 분류되었다. 전체 데이터의 61%에 해당한다.

악성으로 분류된 데이터 결과 중 20건이 양성으로 잘못 분류되었으며, 이는 데이터에 있는 총 600건의 데이터 검사 중 3.3%에 해당한다. 마찬가지로, 양성으로 분류된 데이터 중 34건이 악성으로 잘못 분류되었는데, 이는 모든 데이터의 5.7%에 해당한다.

3. 머신러닝을 이용한 갑상샘 결절 분류 결과

머신러닝을 이용한 훈련 데이터와 테스트 데이터에서 갑상샘 초음파 영상의 결절 분류 정확도(Accuracy), 정밀도(Precision), 특이도(Specificity), 민감도(Sensitivity)를 평가하였다.

SVM 모델은 94%, KNN 모델은 91%의 정확도

(Accuracy) 결과가 나타났다. SVM 모델은 92.3%, KNN 모델은 84.1%의 정밀도(Precision) 결과가 나타났다. SVM 모델은 96.3%, KNN 모델은 91.5%의 특이도(Specificity) 결과가 나타났다. SVM 모델은 89.5%, KNN 모델은 90%의 민감도(Sensitivity) 결과가 나타났다. 결과는 Table 2와 같다.

Table 2. Result of classification using machine learning

Model	Accuracy	Precision	Specificity	Sensitivity
SVM	94%	92.3%	96.3%	89.5%
KNN	91%	84.1%	91.5%	90%

Fig. 8에서 SVM 모델에 대한 ROC 곡선은 전반적으로 KNN 모델과 비교해 ROC곡선이 높으며, 이는 KNN 모델보다 표본 내 성능이 높다는 결과가 나타났다.




Fig. 8. Result of using SVM model ROC curve.

Fig. 9에서 KNN 모델에 대한 ROC 곡선은 전반적으로 SVM 모델과 비교해 ROC곡선이 낮으며, 이는 SVM 모델보다 표본 내 성능이 낮다는 결과가 나타났다.




Fig. 9. Result of using KNN model ROC curve.

IV. DISCUSSION

최근 갑상샘 초음파 검사의 시행 빈도 증가로 인해 갑상샘 결절의 발견율이 높아지고 있다. 이에 대한 정확한 진단과 치료의 중요성이 커지고 있다. 본 연구의 목적은 GLCM과 머신러닝을 활용하여 갑상샘 결절을 자동으로 분류하고 진단하여 감별 진단에 도움을 주고자 하는 것이다.

본 연구는 갑상샘 초음파 영상에서 머신러닝을 활용한 갑상샘 결절 검출 알고리즘을 연구하고, 질병 진단의 초기 단계에서의 적용 및 응용을 알아보려 하였다. GLCM을 사용하여 갑상샘 정상패턴과 갑상샘 결절의 패턴을 분석하는 전처리 과정을 통해 갑상샘 정상과 갑상샘 결절의 감별을 더욱 명확하게 구분 하고자 하였다.

머신러닝을 사용한 실험 결과에서 SVM 모델의 특이도는 96.3%, KNN 모델은 91.5%였고, 민감도는 SVM 모델이 89.5%, KNN 모델이 90%로 나타났다. 민감도와 특이도가 높을수록 머신러닝이 정상과 결절을 정확하게 인식한다는 의미이다. 또한 정상 갑상샘 초음파 영상에서 결절을 구별하는 정확도는 SVM 모델 94%, KNN 모델 91%로 나타났다. 두

모델 모두 90% 이상의 정확도를 나타내었다.

머신러닝을 이용한 의료 영상 자동 판독의 기술은 많은 잠재력을 가지고 있지만 여전히 극복해야 할 제한 사항들이 존재한다. 실험 결과를 통해 확인된 본 연구의 한계점 중 첫 번째는 머신러닝을 적용하기 위한 임상 사례 수가 비교적 적다는 점이다. 두 번째는 ROI 선택 과정에서 임의적인 부분을 선택함으로써 주관적인 판단이 개입될 가능성이 있다. 세 번째는 초음파 영상은 스캔 방향에 따라 영상이 다르게 나타날 수 있다. 네 번째로 한 병원에서 수집된 데이터를 사용한 점이 연구의 한계점으로 판단된다. 마지막으로 실제 임상 적용 시 의료 영상 자동 판독이 정확하게 이루어졌는지 의사와 방사선사가 초음파 검사를 직접 진행하여 비교하는 확인 절차가 추가 될 수 있다는 단점이 있다. 이러한 문제점을 해결하는 것이 향후 연구 과제로 여겨진다.

하지만 본 연구에서 임상 사례의 수가 적음에도 불구하고 머신러닝의 분류 정확도가 두 모델 모두 90% 이상을 나타내었다. 이는 갑상샘 정상과 갑상샘 결절을 분류하는데 머신러닝을 이용할 경우 분류율이 우수하다는 것을 알 수 있다. 따라서 향후 다양한 임상 질병을 대상으로 한 머신러닝 모델 연구와 더 많은 임상 사례를 포함한 연구를 통해, 의료 영상 자동 판독 시스템을 개발한다면 갑상샘 결절의 인식 및 진단뿐만 아니라 연구에 필요한 기초자료로 활용될 수 있을 것이다. 또한 갑상샘 결절 초음파 영상에 익숙하지 않은 의사와 방사선사에게도 갑상샘 정상과 갑상샘 결절을 구분하는 전처리 과정으로 유용하게 활용될 수 있을 것으로 기대된다.

V. CONCLUSION

본 연구는 GLCM과 머신러닝을 이용하여 갑상샘 초음파영상의 결절 분류에 관하여 실험을 진행하였다. 그 결과 SVM 모델의 ROC 곡선은 전반적으로 KNN 모델보다 높게 나타났으며, 이는 KNN 모델보다 SVM 모델의 표본 내 성능이 더 우수하다는 것을 의미한다. 또한 정상 갑상샘 초음파 영상에서 결절을 구별하는 정확도는 SVM 모델 94%, KNN 모델 91%로 SVM 모델의 분류율이 높게 나

타났다. 하지만 두 모델 모두 90% 이상의 정확도를 나타내었으며, 이는 갑상샘 정상과 갑상샘 결절을 분류하는 데 있어 머신러닝이 우수한 성능을 발휘한다는 것을 보여준다.

Reference

- [1] D. S. Ross, "Nonpalpable thyroid nodules--managing an epidemic", *Journal of Clinical Endocrinology & Metabolism*, Vol. 87, No. 5, pp. 1938-1940, 2002. <http://doi.org/10.1210/jcem.87.5.8552>
- [2] G. H. Tan, H. Gharib, "Thyroid incidentalomas: management approaches to nonpalpable nodules discovered incidentally on thyroid imaging", *Annals of Internal Medicine*, Vol. 126, No. 3, pp. 226-231, 1997. <https://doi.org/10.7326/0003-4819-126-3-199702010-00009>
- [3] J. N. Patel, J. Klopper, E. E. Cottrill, "Molecular diagnostics in the evaluation of thyroid nodules: Current use and prospective opportunities", *Frontiers in Endocrinology*, Vol. 14, pp. 1101410, 2023. <http://doi.org/10.3389/fendo.2023.1101410>
- [4] Y. G. Park, E. k. Lee, Y. S. song, S. H. Kang, B. S. Koo, S. W. Kim, D. G. Na, S. K. Baek, S. W. Oh, M. K. Lee, S. W. Lee, Y. A. Lee, Y. S. Lee, J. Y. Lee, D. J. Lee, L. H. Joo, Y. S. Jung, C. K. Jung, Y. Y. Cho, Y. J. Chung, W. B. Kim, K. H. Yi, H. C. Kang, D. J. Park, "2023 Korean Thyroid Association Management Guidelines for Patients with Thyroid Nodules", *International Journal of Thyroidology*, Vol. 16, No. 1, pp. 1-31, 2023. <http://doi.org/10.11106/ijt.2023.16.1.1>
- [5] S. Y. Kim, Y. J. Cho, H. S. Shing, J. E. Oh, D. H. Hong, B. W. Yoo, H. Joe, K. S. Shing, D. Y. Son, "Relationship between the Thyroid Nodules and Metabolic Syndrome in Healthy Adults: Using Health Examination Data at One Medical Institution's Health Examination Center (2020)", *Korean Journal of Family Practice*, Vol. 12, No. 4, pp. 268-273, 2020. <http://doi.org/10.21215/kjfp.2022.12.4.268>
- [6] S. J. Ko, J. S. Lee, S. Y. Ye, C. S. Kim, "Application of Texture Features algorithm using Computer Aided Diagnosis of Papillary Thyroid Cancer in the Ultrasonography", *The Journal of the*

- Korea Contents Association, Vol. 13, No. 5, pp. 303-310, 2013.
<https://doi.org/10.5392/JKCA.2013.13.05.303>
- [7] J. H. Lee, "Research on Ultrasound B-mode Image Aided Diagnosis System Using Bio Big Data and Machine Learning", Journal of the Korean Institute of Electrical and Electronic Material Engineers, Vol. 28, No. 1, pp.13-25, 2015.
<https://koreascience.kr/article/JAKO201507037196246.pdf>
- [8] Vadhiraj, Vijay Vyas, et al., "Ultrasound Image Classification of Thyroid Nodules using Machine Learning Techniques", Journal of Medicina, Vol. 57, No. 6, pp. 527, 2021.
<http://doi.org/10.3390/medicina57060527>
- [9] Y. H. Cho, "A Performance Improvement of GLCM Based on Nonuniform Quantization Method", Journal of Korean Institute of Intelligent Systems, Vol. 25, No. 2, pp. 133-138, 2015.
<https://doi.org/10.5391/JKIIS.2015.25.2.133>
- [10] J. Y. Cho, S. Y. Ye, "Analysis of Malignant Tumor Using Texture Characteristics in Breast Ultrasonograph", Journal of the Institute of Convergence Signal Processing, Vol. 20, No. 2, pp. 70-77, 2019.
<http://dx.doi.org/10.23087/jkicsp.2019.20.2.002>
- [11] J. Y. Cho, C. S. Kim, S. S. Kang, S. J. Ko, S. Y. Ye, "Image Analysis of Computer Aided Diagnosis using Gray Level Co-occurrence Matrix in the Ultrasonography for Benign Prostate Hyperplasia", The Journal of the Korea Contents Association, Vol. 15, No. 3, pp. 184-191, 2015.
<https://doi.org/10.5392/JKCA.2015.15.03.184>
- [12] Z. Nitish, P. Vrushsen, "GLCM Textural Features for Brain Tumor Classification", International Journal of Computer Science, Vol. 9, No. 3, pp. 354-359, 2012. www.IJCSI.org
- [13] S. Poonguzhali, G. Ravindran, "Automatic Classification of Focal Lesions in Ultrasound Liver Images Using Combined Texture Features", Information Technology Journal, Vol. 7, No. 1, pp. 205-209, 2008.
<http://dx.doi.org/10.3923/itj.2008.205.209>
- [14] Y. J. Yang, "A Statistical Approach of the Texture Analysis for the Symptom Classification on the Carotid Plaque Ultrasound Images", Ewha Womans University, Master of Dept. of Computer Science and Engineering, 2007.
<https://www.riss.kr/link?id=T11039145>
- [15] M. Nixon, A. Aguado, *Feature extraction and image processing*. Newnes, Reed Educational and Professional Publishing Ltd. Vol. 30, pp. 747-757, 2002.
- [16] J. H. Shin, "Classification of Diagnostic Factors for Atherosclerosis Using Non-Uniform Rational B-Spline Surface and Support Vector Machine Learning", Sungkyunkwan University, Master of Dept. of Industrial Engineering, 2008.
<https://www.riss.kr/link?id=T11576462>
- [17] H. Drucker, B. Shahrari, D. C. Gibbon, "Support Vector Machines : Relevance Feedback and Information retrieval", Journal of Information Processing & Management, Vol. 38, No. 3, pp. 305-323, 2002.
[http://doi.org/10.1016/S0306-4573\(01\)00037-1](http://doi.org/10.1016/S0306-4573(01)00037-1)

머신러닝과 GLCM을 이용하여 갑상샘 초음파영상의 결절분류에 관한 연구

정예나, 예수영*

부산가톨릭대학교 보건과학대학 방사선학과

요약

본 연구는 갑상샘 초음파 영상에서 정상영상과 결절영상을 GLCM과 머신러닝을 이용하여 분류하고자 하였다. 부산 소재 S병원에 내원하여 갑상샘 초음파를 이용하여 갑상선 결절 진단받은 600명을 대상으로 연구를 진행하였다. 갑상샘 초음파 영상에서 ROI 50 X 50 픽셀 크기로 설정 하고 GLCM을 이용하여 21개의 파라미터와 4가지 각도를 사용하여 갑상샘 정상 패턴과 갑상샘 결절 패턴을 분석하였다. 분석된 자료는 MATLAB 모델 중 SVM모델과 KNN모델을 이용하여 진단 결과가 정상과 결절을 구별할 수 있도록 하였다. 그 결과 갑상샘 결절 분류율의 정확도는 SVM모델은 94%, KNN모델은 91%으로 나타났다. 두 모델 모두 90% 이상의 정확도를 나타내었는데 이는 갑상샘 정상과 갑상샘 결절의 분류를 위해 머신러닝을 이용할 경우 분류율이 우수하다는 것을 알 수 있다. ROC곡선에서도 SVM 모델에 대한 ROC 곡선은 전반적으로 KNN모델과 비교해 ROC곡선이 높으며, 이는 KNN모델보다 표본 내 성능이 높다는 결과가 나타났다. 이러한 결과를 바탕으로 SVM 모델이 갑상샘 결절 진단에서 높은 정확도를 보여주었다. 이 결과는 향후 의료 진단 보조 도구로서의 연구에 기초자료로 활용될 수 있으며, 머신러닝 기술이 의료 서비스의 질적 개선에 기여할 것으로 기대된다.

중심단어: 갑상샘결절초음파, GLCM, 머신러닝, SVM, KNN

연구자 정보 이력

	성명	소속	직위
(제1저자)	정예나	부산가톨릭대학교 보건과학대학 방사선학과	대학원생
(교신저자)	예수영	부산가톨릭대학교 보건과학대학 방사선학과	교수