

## 라디오믹스 기반 직장암 수술 위험도 예측을 위한 MRI 반자동 선택 바이오마커 검증 연구

백영서<sup>1</sup> · 김영재<sup>1,2,3</sup> · 전영배<sup>4</sup> · 황태식<sup>4</sup> · 백정흠<sup>4\*\*</sup> · 김광기<sup>1,2,3\*</sup>

<sup>1</sup>가천대길병원 의료기기 R&D센터, <sup>2</sup>가천대학교 의과대학 의공학교실, <sup>3</sup>가천융합의과학원 의용생체공학과,  
<sup>4</sup>가천대학교 의과대학 길병원 외과학교실 대장항문외과

### A Study on MRI Semi-Automatically Selected Biomarkers for Predicting Risk of Rectal Cancer Surgery Based on Radiomics

Young Seo Baik<sup>1</sup>, Young Jae Kim<sup>1,2,3</sup>, Youngbae Jeon<sup>4</sup>, Tae-sik Hwang<sup>4</sup>,  
Jeong-Heum Baek<sup>4\*\*</sup> and Kwang Gi Kim<sup>1,2,3\*</sup>

<sup>1</sup>Medical Devices R&D Center, Gil Medical Center

<sup>2</sup>Department of Biomedical Engineering, College of Medicine, Gachon University

<sup>3</sup>Department of Health Sci. & Technol., Gachon Advanced Institute for Health Sci. & Technology (GAIHST),  
Gachon University, Lee Gil Ya Cancer and Diabetes Institute

<sup>4</sup>Division of Colon and Rectal Surgery, Department of Surgery, Gil Medical Center, Gachon University College of Medicine  
(Manuscript received 11 November 2022 ; revised 23 December 2022 ; accepted 24 December 2022)

11

**Abstract:** Currently, studies to predict the risk of rectal cancer surgery select MRI image slices based on the clinical experience of surgeons. The purpose of this study is to semi-automatically select and classify 2D MRI image slides to predict the risk of rectal cancer surgery using biomarkers. The data used were retrospectively collected MRI imaging data of 50 patients who underwent laparoscopic surgery for rectal cancer at Gachon University Gil Medical Center. Expert-selected MRI image slices and non-selected slices were screened and radiomics was used to extract a total of 102 features. A total of 16 approaches were used, combining 4 classifiers and 4 feature selection methods. The combination of Random Forest and Ridge performed with a sensitivity of 0.83, a specificity of 0.88, an accuracy of 0.85, and an AUC of  $0.89 \pm 0.09$ . Differences between expert-selected MRI image slices and non-selected slices were analyzed by extracting the top five significant features. Selected quantitative features help expedite decision making and improve efficiency in studies to predict risk of rectal cancer surgery.

**Key words:** Rectal cancer, Radiomics, Biomarker, Quantitative

\*Corresponding Author : Kwang Gi Kim  
Gil Medical Center, Gachon University College of Medicine,  
38-13, Dokjeom-ro 3beon-gil, Namdong-gu, Incheon, Republic  
of Korea

Tel: +82-32-458-2770

E-mail: kimkg@gachon.ac.kr

\*\*Corresponding author: Jeong-Heum Baek

Division of Colon and Rectal Surgery, Department of Surgery,  
Gil Medical Center, Gachon University College of Medicine, 21  
Namdong-daero 774beon-gil, Namdong-gu, Incheon 21565,  
Republic of Korea

Tel: +82-32-460-3241

E-mail: gsbaek@gilhospital.com

본 연구는 가천대 길병원(FRD2020-19)과 경기도의 경기도 지역협력연구센터 사업의 지원을 받아 수행한 연구임[GRRC-Gachon2020 (B01), AI기반 의료영상분석].

## I. 서론

직장암은 직장에 생긴 악성 종양으로, 남녀 모두에서 세 번째로 발병 빈도수가 높은 암이다[1]. 직장암은 좁은 골반강내에 위치하여 수술의 난이도가 높아서 수술적 치료 전에 해부학적 구조를 잘 이해하는 것이 중요하다[2]. 이러한 이유로 직장암의 병기를 결정하고 진단 후 치료 방침 결정에 있어서 자기공명영상(Magnetic Resonance Imaging, MRI) 검사가 필수적으로 진행되고 있다[3]. MRI는 직장 종양 및 직장간막과 그를 둘러싸고 있는 골반의 구조를 잘 보여주고 있어 수술 시 난이도를 예측할 수 있다[4]. 이

러한 영상 분석은 직장암에 대한 평가가 가능할 뿐만 아니라 골반 전체에 해부학적 정보를 제공하는 도구이다[5].

최근 직장암의 수술적 접근방법은 개복수술보다는 최소 침습 수술인 직장간직장절제술이 보편화되고 있다[6]. 수술의 난이도는 다양한 임상적 요인과 환자의 골반 구조에 영향을 받기 때문에 수술 전에 골반 구조를 검사하는 것이 중요하다[7]. 따라서 이러한 수술 전 평가는 수술의 어려움을 예측하고 더 나은 종양학적 결과를 얻는 데 도움이 될 수 있다. 직장암 수술 위험도 예측을 위한 연구에 대한 여러 연구가 보고되고 있다[8-10]. Yamamoto T 등은 직장암 수술에서 수술 난이도 예측에 임상변수와 MRI 영상 골반 측정의 영향을 강조하였다[8]. Lee JM 등은 골반저 근육의 수술 난이도에 따른 직장암 절제의 어려움을 예측하는데 Mann-Whitney U 테스트 통계 방법을 사용하였고, 수술 기간의 독립적인 인자를 예측하는 연구결과를 발표하였다[9]. 그러나 수동 묘사는 높은 수준의 전문 지식이 필요하기 때문에 시간이 많이 걸리는 절차이다[10]. MRI 직장암 수술 위험도 예측을 위한 연구에서 직장과 직장간막이 잘 보이는 MRI 영상을 외과 전문의가 선별하여 직장암 수술 위험도 예측의 임상적 가치를 평가하는 데는 많은 시간과 노력이 필요하다. 이러한 한계점을 극복하기 위해 MRI 영상에서 외과 전문의가 선택한 슬라이스와 그 외의 슬라이스를 나누어 차이점을 분석하는 것이 필요하다.

디지털 영상처리 기법(Digital Image Processing, DIP) 및 기계 학습(Machine Learning, ML)과 더불어 외과 전문의의 진단을 보조하기 위한 컴퓨터 보조 진단(Computer-Aided Diagnosis, CAD) 기법들이 제시되고 있다[11]. 디지털 의료 영상에서의 대표적인 특징 추출은 영상에서 얻은 정량적 특징을 추출하는 라디오믹스(radiomics) 기법이 이용된다[12]. 사람의 눈으로 감지할 수 없는 라디오믹스를 이용한 의료 영상에 대한 분석은 통계적, 수학적 추출을 통해 인공지능 분야의 분석 방법에 큰 영향을 미쳤다[13]. 질감, 이미지, 모양 정보의 차이를 라디오믹스를 통해 정량화할 수 있으므로 이미지 해석에서 외과 전문의의 주관적인 경험의 한계를 극복할 수 있다[14]. Zhang S 등은 MRI 영상 기반 라디오믹스의 항암화학 방사선요법에 대한 병리학적 치료 반응, 림프절 상태, 종양의 이질성 등을 분석하였다[15]. 육안으로 인식하기 어려운 MRI 영상에서 다양한 종류의 특징들을 추출하여 생체지표가 될 수 있다[16]. Kniep HC 등은 MRI 영상을 기반으로 뇌 종양의 전이성 종양 유형을 예측하는 지표의 가능성을 조사하였다[17]. 그러나 수술의 어려움을 반영하여 골반계측의 필수적인 MRI 영상 슬라이스를 육안으로 고르기 때문에 재현성이 떨어진다. 또한, 동일한 사람이

정확히 같은 MRI 영상 슬라이스를 선택하는 것은 더 어려운 작업이다. 라디오믹스 기반 외과 전문의가 선택한 직장암 MRI 영상 슬라이스 분석에 대한 연구는 필요하다. 외과 전문의가 선택한 직장암 MRI 영상에서 라디오믹스 특징을 추출하여 정량적 판단이 가능한 생체지표를 선정할 수 있다. 이러한 생체지표를 통한 정량적인 진단은 외과 전문의의 임상적 경험에 크게 의존하는 주관적인 판단의 한계를 극복할 수 있다. 또한 생체지표는 인공지능 모델의 진단 결과를 설명할 수 있는 근거가 되어 모델을 설계 가능하다는 장점이 있다. 하지만 외과 전문의가 선택한 직장암 MRI 영상에서 라디오믹스를 통해 유의한 특징을 찾고 생체지표를 선정하는 연구는 보고된 바가 적다.

따라서 본 연구에서는 외과 전문의가 선택한 직장암 MRI 영상에서 라디오믹스 특징들을 추출하고 인공지능으로 분석하여 특징 간의 중요도를 탐색한다. 중요도에 의해 선별된 상위 5개의 특징을 이용해서 분류기를 학습시키고, 외과 전문의가 선택한 직장암 MRI 영상 슬라이스와 그 외의 슬라이스의 특징 차이를 분석하고자 한다.

## II. 연구 방법

### 1. 개발환경

본 연구의 실험 환경은 NVIDIA GeForce GTX 1050 Ti(NVIDIA, Santa Clara, Calif) 그래픽 처리 장치와 2.90 GHz Intel Core i7-10700(Intel, Santa Clara, Calif) CPU 및 32GB RAM으로 구성된 시스템을 사용하였으며, Windows 10 pro 운영체제에서 수행하였다. 실험 학습은 파이썬(Python, version 3.6.13)을 통해 모델을 학습하였다. 특징을 추출하기 위해 파이썬 기반 오픈소스 패키지인 파이러디오믹스(Pyradiomics, version 3.0.1, Python Software Foundation)를 사용하였다. 추출된 특징을 선택하고 분류하기 위해 파이썬 기반 오픈 소스 인공지능 라이브러리인 사이킷런(Scikit-learn, version 0.24.2)을 사용하였다. 정량적 측정 결과에 대한 통계 분석은 MedCalc version 14.8.1(MedCalc Software, Ostend, Belgium) 프로그램으로 수행하였다.

### 2. 데이터 수집

실험에서 사용된 데이터는 가천대학교 길병원에서 2017년 1월부터 2020년 12월까지 직장암으로 복강경 수술을 받은 총 50명 환자의 2차원 MRI Axial 영상 데이터를 후향적으로 수집하였다(IRB No. GCIRB2021-311). 모든 수술 방법은 단일 외과에 의한 저위전방절제술(low anterior resection) 받은 환자이고, 응급 수술, 개복수술, 복회음절제술, 괄약근간 절제술을 받은 환자는

제외되었다. 직장암 영상은 데이터마다 크기가 다른 MRI 영상 데이터를 사용하였다. 파이라디오믹스 패키지에서 직장암 영역의 원본 영상을 분석 가능한 파이썬(Python)에서 제공하는 파이다이콤(Pydicom) 라이브러리를 이용하여 DICOM 파일로 변환하였다. 데이터는 외과 전문의가 선택한 직장 바깥쪽의 원으로 구별되는 중간 직장 MRI 영상 50장과 중간 직장 영역이 보이는 기준 가장 멀리 떨어진 중간 직장 MRI 영상 50장을 선별하였다. 수집된 직장암 MRI 영상에 대해 학습을 위한 관심 영역(Region of interest, ROI) 레이블링은 Coreline Soft의 Aview 프로그램을 사용하여 전문의 검수 과정을 통해 종양에 대한 관심 영역을 표시하였다(그림 2a). 수집된 100장의 영상 데이터 중, 80장은 학습 데이터(training data)로 사용되었고, 20장은 테스트 데이터(test data)로 사용되었다. 학습 데이터는 40장의 외과 전문의가 선택한 직장암 MRI 영상 데이터와 40장의 그 외의 데이터로 구성되었고, 테스트 데이터는 10장의 외과 전문의가 선택한 직장암 MRI 영상 데이터와 10장의 그 외의 데이터로 구성되었다.

### 3. 데이터 전처리

라디오믹스의 통계적 계산을 하기 위한 특징 추출은 단일채널로만 입력을 받기 때문에 그레이스케일로 변환하여 수행하였다. 수동으로 표시한 직장암 ROI를 활용하여 마스크 이미지로 변환하여 특징 추출에 사용했다. 영상 데이터 이미지는 가로, 세로 비율이 다르기 때문에 크기를 조정하는 과정이 필요하다. 그림 1과 같이 원본 이미지의 너비에 맞추어 빈 공간을 채우는 방식(zero padding)을 이용하여 모든 이미지를 256×256 픽셀로 변환하여 실험에 사용하였다.

### 4. 라디오믹스 기반 특징 추출

본 연구에서는 라디오믹스 기반의 특징 추출을 수행하여

외과 전문의가 선택한 직장암 MRI 영상의 특징을 정량적인 수치로 표현하였다. 영상의 대한 평균, 분산과 같은 1차 히스토그램 통계(First Order) 18개, 형질 특징(2D Shape) 9개[18], 현재 픽셀과 이웃하는 픽셀의 밝기 값의 상관관계를 대비, 에너지, 동질성 같은 특징을 통계량으로 계산하여 나타내는 Gray Level Co-occurrence Matrix (GLCM)[19] 24개, 떨어져 있는 픽셀 사이의 밝기 값들의 발생 빈도를 계산하여 나타낸 Gray Level Dependence Matrix(GLDM)[20] 14개, 동일한 밝기 값을 가진 픽셀이 연속적으로 나타나는 실행 길이를 분석하는 Gray Level Run Length Matrix(GLRLM)[21] 16개, 동일한 그레이 레벨로 연결된 픽셀의 크기와 강도를 탐색하는 Gray Level Size Zone Matrix(GLSZM)[22] 16개, 해당 픽셀에 인접한 픽셀들의 거칠기, 대비, 혼잡도 같은 차이를 분석하는 Neighborhood Gray Tone Difference Matrix(NGTDM) [23] 5개로, 총 102개의 특징을 추출하였다(그림 2b).

### 5. 특징 선택

추출된 많은 양의 라디오믹스 특징은 모델의 학습 시간을 늘리고 성능을 떨어뜨릴 수 있다[24]. 따라서, 효율적인 인공지능을 하기 위해 분류에 유의미한 특징을 선택해야 한다. 분류 모델의 정밀도를 높이기 위해 특징 선택을 진행하였다.

특징 선택에서는 Least Absolute Shrinkage and Selection Operator(LASSO), Ridge regularization(Ridge), Recursive Feature Elimination(RFE), Sequential Feature Selector(SFS) 네 가지 기법을 사용하였다(그림 2c). LASSO와 Ridge는 특정 회귀 계수에 패널티를 부여하여 정규화를 하는 방법이다[25]. RFE는 서브세트(subset)를 고려하여 가중치가 가장 낮은 특징을 제거하는 방법이다[26]. SFS는 서브세트의 교차 검증(cross validation) 점수를 최대화하는 기능을 찾고 추가하는 방법이다.




그림 1. MRI 영상 슬라이스 데이터 처리 결과 (a) 원본 (b) 관심 영역 이미지 (c) 마스크 이미지  
Fig. 1. Result of MRI image slice data processing. (a) Original (b) ROI image (c) Mask image

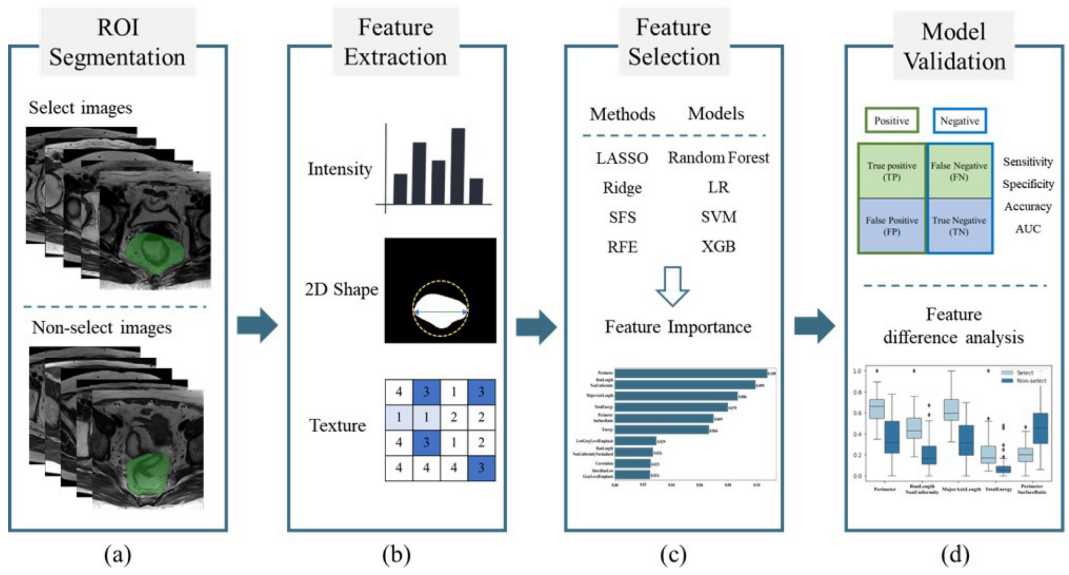


그림 2. 라디오믹스를 통한 직장암 MRI 영상 슬라이스 선택 분류 연구 흐름도  
 Fig. 2. The flowchart for rectal cancer MRI image slice selection classification using radiomics

6. 학습 모델

분류 모델의 정밀도를 높이기 위해 선택된 특징들을 Random Forest(RF), Extreme Gradient Boosting(XGB), Logistic Regression(LR), Support Vector Machine(SVM) 네 가지의 분류기를 통해 학습과 분류하였다. 학습한 모델의 성능과 특징 가중치를 분석하여 어떤 라디오믹스 특징이 생체지표로 사용 가능한지 도출할 것이다. RF는 무작위의 의사 결정 트리를 독립적으로 학습시킨 후, 예측함으로써 정밀도를 개선하고 과적합을 제어하는 배깅(bagging) 방식의 앙상블 학습 방법이다[27]. XGB는 의사 결정 트리가 이전 트리의 오차를 보정하는 방식으로 손실을 최소화하는 부스팅(boosting) 방식의 앙상블 학습 방법이다[28]. LR은 회귀 계수의 해석이 가능하고 클래스에 속할 확률을 계산하는 학습 방법이다[28]. SVM은 분류와 예측이 가능하고 과적합 경우가 적고 오류 데이터에 대한 영향이 적은 학습 방법이다[28](그림 2c).

7. 모델 평가 지표

모델을 평가하기 위한 지표로는 먼저 실제 값과 모델의 예측 값을 비교하여 얻은 진양성(True Positive, TP), 위양성(False Positive, FP), 위음성(False Negative, FN), 진음성(True Negative, TN)값을 이용해, 병변 분류 모델의 평가를 위해 재현율(Recall)와 특이도(specificity), 정밀도(Precision)를 얻었다. 직장암 MRI 영상 슬라이스 반자동 선택 분류 성능을 평가하기 위해 양성 클래스 탐지와 음성 클래스 탐지의 중요도가 비슷한 ROC의 곡선 아래 영역을 나타내는 Area Under the Curve(AUC) 분석을

수행하였다(그림 2d).

III. 연구 결과

본 연구에서는 분류기 4가지와 특징 선택 기법 4가지를 조합하여 총 16가지 접근 방식을 외과 전문의가 선택한 직장암 MRI 영상 슬라이스와 그 외의 슬라이스의 분류 성능 결과를 그림 3에 제시하였다. RF 분류기와 Ridge 특징 선택 기법의 조합이 AUC 0.89로 우수한 성능을 보

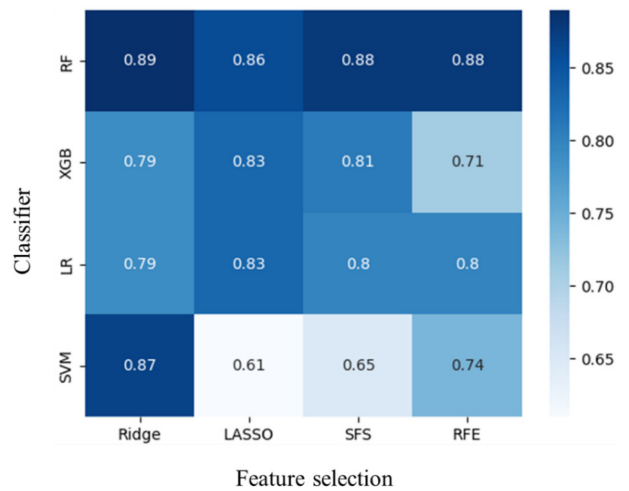


그림 3. MRI 영상 슬라이스 선택 분류 성능을 확인하기 위한 성능 평가 분석 결과. 제시된 수치는 분류 성능의 AUC.  
 Fig. 3. Performance evaluation analysis results to confirm the MRI image slice selection classification performance. Presented numerical values indicate AUC score.

표 1. RF와 Ridge, LASSO, SFS, RFE 조합의 재현율, 특이도, 정밀도, AUC의 분석결과

Table 1. Recall, specificity, precision, and AUC analysis results for RF and Ridge, LASSO, SFS, and RFE combinations

	Recall	Specificity	Precision	AUC
RF + Ridge	0.83	0.88	0.85	0.89±0.09
RF + LASSO	0.82	0.66	0.83	0.86±0.12
RF + SFS	0.85	0.73	0.86	0.88±0.11
RF + RFE	0.84	0.75	0.87	0.88±0.08

였다. SVM 분류기와 LASSO 특징 선택 기법의 조합은 상대적으로 낮은 성능을 보였다.

외과 전문의가 선택한 직장암 MRI 영상 슬라이스와 그 외의 슬라이스의 분류를 검증하기 위해서 50건의 테스트 데이터를 사용하여 학습 모델 간의 성능을 검증하였다. RF 분류기와 Ridge, LASSO, SFS, RFE 특징 선택 방법을 통한 분류 성능의 재현율, 특이도, 정밀도, AUC 값을 표 1에 나타냈다.

RF와 Ridge의 조합이 재현율 0.83, 특이도 0.88, 정밀도 0.85, AUC 0.89±0.09로 높은 성능을 보였다. 반면, RF와 LASSO의 조합은 재현율 0.82, 특이도 0.66, 정밀도 0.83, AUC 0.86±0.12으로 낮은 성능을 보였다.

직장암 MRI 영상 슬라이스 선택 분류에 유의한 특징을 찾기 위해서 가장 성능이 높았던 RF와 Ridge 조합의 상위 5개의 특징 중요도 값을 그림 4에 나타냈다. 상위 5개 특징들은 Perimeter, Run Length Non Uniformity, Major Axis Length, Total Energy, Perimeter Surface Ratio이다. 2D Shape의 Perimeter는 특징의 다각형 부분의 전체 둘레 길이를 나타낸다. GLRLM의 Run Length Non Uniformity은 같은 그레이 레벨 값을 가진 연속 픽셀의 수로 정의되는 유사성을 이미지 전체에서 측정된 값이며, 값이 낮을수록 균일함을 나타낸다. 2D Shape의 Major Axis Length는 픽셀 중심의 물리적 좌표를 사용하여 ROI를 둘러싸는 타원체의 가장 큰 축 길이를 나타낸다.

First Order의 Total Energy는 복셀 부피로 조정된 에너지 기능의 값을 나타낸다. 2D Shape의 Perimeter Surface Ratio는 표면에 대한 둘레 비율로, 값이 낮을수록 원형 모양을 나타낸다.

특징 선택 기법을 이용한 특징 중요도를 통해 나온 상위 5개 항목들이 실제 라디옴으로 추출한 특징 값을 비교해볼 때 차이가 있는지 분석하기 위해 진행하였다. 외과 전문의가 선택한 직장암 MRI 영상 슬라이스와 그 외의 슬라이스의 특징 차이를 분석하기 위해 상위 5개의 특징들의 값 분포를 그림 5에 나타냈다. 또한, 통계학적으로 유의미한 차이를 보였다( $p < 0.001$ ). Perimeter는 특징의 다각형 부분의 전체 둘레 길이를 나타낸다. Run Length Non Uniformity는 값이 낮을수록 더 균일함을 나타낸다. Major Axis Length는 ROI를 둘러싸는 타원체의 가장 큰 축 길이를 나타낸다. Total Energy는 복셀 부피로 조정된 에너지 기능의 값을 나타낸다. Perimeter Surface Ratio는 값이 낮을수록 원형 모양에 더 가깝다. Perimeter, Run Length Non Uniformity, Major Axis Length, Total Energy 특징에서 외과 전문의가 선택한 직장암 MRI 영상 슬라이스가 그 외의 슬라이스보다 높은 값을 가진 것으로 보인다. Perimeter Surface Ratio 특징에서 그 외의 슬라이스가 외과 전문의가 선택한 직장암 MRI 영상 슬라이스보다 낮은 값을 가진 것으로 보인다.




그림 4. RF 분류와 Ridge 특징 선택 기법 조합의 특징 중요도 분석 결과

Fig. 4. Feature importance analysis results of RF classifier using Ridge feature selection method

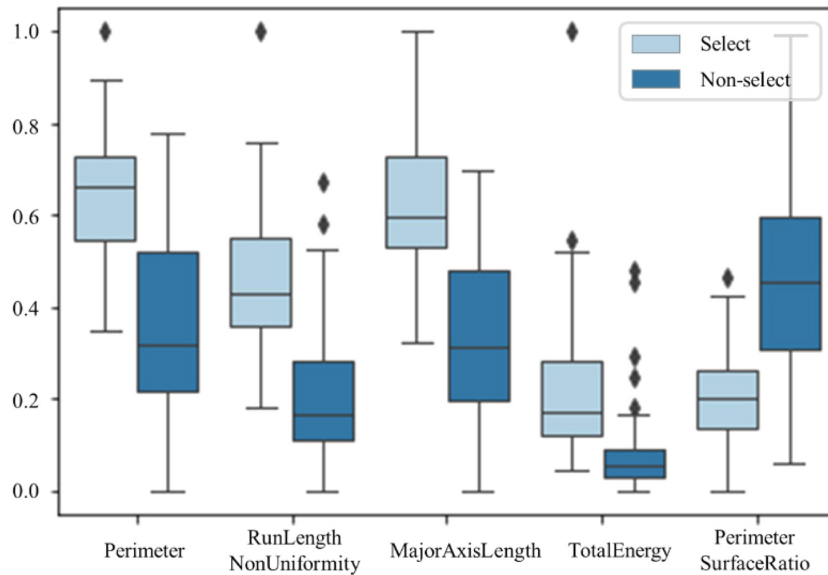


그림 5. MRI 영상 슬라이스 선택 분류에서 RF와 Ridge 조합의 유의한 특징 차이 분포  
 Fig. 5. Analysis of Significant Feature Differences of RF and Ridge Combinations in MRI Image Slice Selection Classification ( $p < 0.001$ ).

#### IV. 고찰 및 결론

16

본 연구에서는 외과 전문의의 임상적 경험에 크게 의존하는 주관적인 판단의 한계를 극복하기 위해서 라디오믹스 특징을 추출하여 정량적 분석을 진행하였다. 외과 전문의가 선택한 직장암 MRI 영상 슬라이스와 그 외의 MRI 영상 슬라이스의 인공지능 기반 특징 차이를 비교 분석하였다. 분류기 4가지와 특징 선택 기법 4가지를 조합하여 총 16가지 모델의 예측 결과를 비교 분석하여 성능을 평가하였다. 분석 결과, RF와 Ridge의 조합은 재현율 0.83, 특이도 0.88, 정밀도 0.85, AUC  $0.89 \pm 0.09$ 로 가장 높은 성능을 보였다. Ridge 기법은 회귀모델의 모든 독립변수를 그대로 보존해서 적용하기 때문에 특징 선택 기법 중 제일 적합하다. 또한, 변수 간 상관관계가 높은 상황에서 좋은 예측 성능을 가져왔다. RF와 LASSO의 조합이 재현율 0.82, 특이도 0.66, 정밀도 0.83, AUC  $0.86 \pm 0.12$ 로 가장 낮은 성능을 보였다. LASSO 기법은 한 개의 변수만 채택하기 때문에 정보가 손실됨에 따라 정확성이 떨어져 분류 정확도가 낮게 나온 것으로 판단된다. RF와 SFS의 조합은 재현율 0.85, 특이도 0.73, 정밀도 0.86, AUC  $0.88 \pm 0.11$ 의 성능을 보였다. SFS는 특징을 추가하면서 정해진 개수의 특징이 선택될 때까지 한계를 보완하는 특징들을 선택하기 때문에 적절한 특징을 찾은 것으로 판단된다. RF와 RFE의 조합이 재현율 0.84, 특이도 0.75, 정밀도 0.87, AUC  $0.88 \pm 0.08$ 의 성능을 보였다. RFE 기법은 반복적으로 특징을 제거하면서 최적의 특징

조합을 선택한다. 최종적으로 특징 개수를 선택하는 것은 각 특징의 한계를 보완하는 특징들을 선택할 가능성을 크게 하기 때문에 적절한 특징을 찾은 것으로 판단된다.

MRI 영상 슬라이스 선택 분류 성능이 높게 나온 RF 분류기와 Ridge 특징 선택 기법 조합에서 유의미한 상위 5개의 특징들은 Perimeter, Run Length Non Uniformity, Major Axis Length, Total Energy, Perimeter Surface Ratio임을 확인할 수 있다. 외과 전문의가 선택한 직장암 MRI 영상 슬라이스는 그 외의 MRI 영상 슬라이스보다 특징의 다각형 부분의 전체 둘레 길이를 나타내는 Perimeter 값이 더 크다. 외과 전문의가 선택한 직장암 MRI 영상 슬라이스는 그 외의 MRI 영상 슬라이스보다 ROI를 둘러싸는 타원체의 가장 큰 축길이를 나타내는 Major Axis Length 값이 더 크다. 외과 전문의가 선택한 직장암 MRI 영상 슬라이스는 그 외의 MRI 영상 슬라이스보다 복셀 부피로 조정된 에너지 기능의 값을 나타내는 Total Energy 값이 더 크다. 외과 전문의가 선택한 직장암 MRI 영상 슬라이스는 그 외의 MRI 영상 슬라이스보다 Perimeter Surface Ratio 값이 낮아 원형 모양에 더 가깝다. 이러한 특징들은 통계학적으로 유의미한 차이를 보인 것으로 고려되어 특징 중요도로 뽑혔을 것이라 생각된다. 따라서 해당 특징들이 직장암 MRI 영상 슬라이스 선택 분류의 생체지표로 사용 가능할 것으로 보인다.

라디오믹스는 의료 이미지에서 다양한 특징을 추출하는 방법으로 직장암 환자의 치료 과정을 계획하기 위해 반드시 진행하는 MRI 영상 검사로부터 다양한 정보를 추출하였다. 또한, 라디오믹스 특징을 이용하여 학습 및 예측하여 우리 눈에 보이지 않는 정보로부터 정량적으로 분석할 수 있는 데이터를 얻어내고자 하였다. 외과 전문가가 선택한 MRI 영상 슬라이스와 그 외의 MRI 영상 슬라이스의 특징을 정량적인 수치로 표현하기 위해 MRI 영상에서 라디오믹스 기반의 특징 추출을 수행하였다. 아직 라디오믹스의 결과들이 외과 전문의에게 만족할 만큼 최적화된 정보를 제공하기에는 부족하다. 향후에 추가 데이터 수집을 통한 재학습과 이미지 전처리 알고리즘을 개발하여 학습 모델의 성능을 고도화해 나갈 것이다. 의료 분야에 인공지능 알고리즘이 최적화가 되면 기존의 이미지 전처리 과정의 한계는 많이 개선되거나 극복될 것으로 보인다. 더 많은 데이터를 확보하여 더 좋은 예측 모델을 만들어 추가 분석 진행 시, MRI 영상을 통해 슬라이스 선택을 비침습적으로 검토함으로써 환자의 필요한 유전적 정보를 도출하여 표적치료가 효과적으로 진행될 것으로 판단된다. 형태적 정보를 정량화하기 위해서는 후처리를 별도로 수행하여 임상 적합성을 높이는 것이 필요하다. 본 연구에 사용된 데이터 수는 알고리즘을 학습시키고 성능을 평가하기에 충분하지 않다는 제한점이 있고, 데이터의 규모는 연구 결과의 신뢰성에도 중요한 역할을 하므로, 추후 이를 보완한 후속 연구가 필요하다.

연구는 외과 전문가가 선택한 MRI 영상 슬라이스와 그 외의 MRI 영상 슬라이스의 특징 차이 분석을 진행하였다. 이는 외과 전문가가 환자의 직장암 수술 위험도를 예측할 때 효율적으로 진행하는 데 기여할 것으로 판단된다. MRI 영상 슬라이스 선택에서의 정량적인 특징은 자동화하는 데 응용이 가능하다. 직장암 수술 위험도 예측을 위한 연구에서 정량적 특징은 외과전문의의 주관적인 판단의 한계점을 극복하여 빠른 판단력과 효율성을 높이는 데 유용할 것으로 예상된다.

## Reference

- [1] Valentini V, Beets-Tan R, Borras JM, Krivokapić Z, Leer JW, Pählman L, Rödel C, Schmoll HJ, Scott N, Velde CVD, Verfaillie C. Evidence and research in rectal cancer. *Radiotherapy and Oncology*. 2008;87(3):449-474.
- [2] Enker WE. Total mesorectal excision—the new golden standard of surgery for rectal cancer. *Annals of medicine*. 1997;29(2):127-133.
- [3] Shihab OC, Moran BJ, Heald RJ, Quirke P and Brown G. MRI staging of low rectal cancer. *European radiology*. 2009;19(3):643-650.
- [4] Brown G, Daniels IR, Richardson C, Revell P, Peppercorn D, Bourne M. Techniques and trouble-shooting in high spatial resolution thin slice MRI for rectal cancer. *The British journal of radiology*. 2005;78(927):245-251.
- [5] Akiyoshi T, Kuroyanagi H, Oya M, Konishi T, Fukuda M, Fujimoto Y, Ueno M, Miyata S, Yamaguchi T. Factors affecting the difficulty of laparoscopic total mesorectal excision with double stapling technique anastomosis for low rectal cancer. *Surgery*. 2009;146(3):483-489.
- [6] Chen J, Sun Y, Chi P and Sun BMRI pelvimetry-based evaluation of surgical difficulty in laparoscopic total mesorectal excision after neoadjuvant chemoradiation for male rectal cancer. *Surgery today*. 2021;51(7):1144-1151
- [7] Escal L, Nougaret S, Guiu B, Bertrand MM, de Forges H, Tetreau R, Thézenas S, Rouanet P. MRI-based score to predict surgical difficulty in patients with rectal cancer. *Journal of British Surgery*. 2018;105(1):140-146.
- [8] Yamamoto T, Kawada K, Kiyasu Y, Itatani Y, Mizuno R, Hida K, Sakai Y. Prediction of surgical difficulty in minimally invasive surgery for rectal cancer by use of MRI pelvimetry. *BJS Open*. 2020;4(4):666-677.
- [9] Lee JM, Han YD, Cho MS, Hur H, Min BS, Lee KY, Kim NK. Prediction of transabdominal total mesorectal excision difficulty according to the angle of pelvic floor muscle. *Surgical Endoscopy*. 2020;34(7):3043-3050.
- [10] Trebeschi S, van Griethuysen JJM, Lambregts DMJ, Lahaye MJ, Parmar C, Bakers FCH, Peters NHGM, Beets-Tan RGH and Aerts HJWL. Deep learning for fully-automated localization and segmentation of rectal cancer on multiparametric MR. *Scientific reports*. 2017;7(1):1-9.
- [11] Doi K. Current status and future potential of computer-aided diagnosis in medical imaging. *The British journal of radiology*. 2005;78(suppl\_1):s3-s19
- [12] Kumar V, Gu Y, Basu S, Berglund A, Eschrich SA, Schabath MB, Foster K, Aerts HJWL, Dekker A, Fenstermacher D, Goldgof DB, Hall LO, Lambin P, Balagurunathan Y, Gateno RA, Gillies RJ. Radiomics: the process and the challenges. *Magnetic Resonance Imaging*. 2012;30(9):1234-1248.
- [13] Van Griethuysen JJM, Fedorov A, Parmar C, Hosny A, Aucoin N, Narayan V, Beets-Tan RGH, Fillion-Robin JC, Pieper S, Aerts HJWL. Computational Radiomics System to Decode the Radiographic Phenotype. *Cancer research*. 2017;77(21):e104-e107.
- [14] Machicado JD, Koay EJ, Krishna SG. Radiomics for the Diagnosis and Differentiation of Pancreatic Cystic Lesions. *Diagnostics*. 2020;10(7):505.
- [15] Zhang S, Yu M, Chen D, Li P, Tang B, Li J. Role of MRI-based radiomics in locally advanced rectal cancer. *Oncology Reports*. 2022;47(2):1-10.
- [16] Yip SSF, Aerts HJWL. Applications and limitations of radiomics. *Physics in Medicine & Biology*. 2016;61(13):R150.
- [17] Knip HC, Madesta F, Schneider T, Hanning U, Schonfeld MH, Schon G, Fiehler J, Gauer T, Werner R, Gellissen S. Radiomics of brain MRI: utility in prediction of metastatic tumor type. *Radiology*. 2019;290(2):479-487.
- [18] Kandemirli SG, Chopra S, Pyiya S, Ward C, Locke T, Soni N, Srivastava S, Jones K, Bathla G. Presurgical detection of brain invasion status in meningiomas based on first-order histogram-based texture analysis of contrast enhanced imaging. *Clinical neurology and neurosurgery*. 2020;198:106205.
- [19] Mohanaiah P, Sathyanarayana P, GuruKumar I. Image tex-

- ture feature extraction using GLCM approach. *International journal of scientific and research publications*. 2013;3(5):1-5.
- [20] Ahmadi N, Akbarizadeh G. Iris tissue recognition based on GLDM feature extraction and hybrid MLPNN-ICA classifier. *Neural Computing and Applications*. 2020;32(7):2267-2281.
- [21] Sohail ASM, Bhattacharya P, Mudur SP, Krishnamurthy S. Local relative GLRLM-based texture feature extraction for classifying ultrasound medical images. 2011 24th Canadian Conference on Electrical and Computer Engineering (CCECE). 2011;:001092-001095.
- [22] Thibault G, Angulo J, Meyer F. Advanced statistical matrices for texture characterization: Application to DNA chromatin and microtubule network classification. 2011 18th IEEE International Conference on Image Processing. 2011;53-56.
- [23] Amadasun M, King R. Textural features corresponding to textural properties. in *IEEE Transactions on Systems, Man, and Cybernetics*. 1989;19(5):1264-1274.
- [24] Chandrashekar G, Sahin F. A survey on feature selection methods. *Computers & Electrical Engineering*. 40.1. 2014; 40(1):16-28.
- [25] Lu M. Embedded feature selection accounting for unknown data heterogeneity. *Expert Systems with Applications*. 2019; 119:350-361
- [26] Yan K, Zhang D. Feature selection and analysis on correlated gas sensor data with recursive feature elimination. *Sensors and Actuators B: Chemical*. 2015;212:353-363.
- [27] Biau G, Scornet E. A random forest guided tour. *TEST*. 2016;25(2):197-227.
- [28] Verma C, Illés Z, Sttofová V. Real-time classification of national and international students for ICT and mobile technology: an experimental study on Indian and Hungarian University. *Journal of Physics: Conference Series*. 2020;1432(1): 012091.