

건강설문조사 데이터를 활용한 인공지능 알고리즘 기반 여성의 골관절염 및 골다공증 진단 예측 모델 개발

이도윤¹, 김정은², 박휘주³, 정홍기⁴, 조석현*
계명대학교¹, 한남대학교², 연세대학교³, 국립금오공과대학교⁴,
*University of California, San Diego (UCSD)

newldy151@gmail.com, 414wjddms@gmail.com, parkhwijoo@gmail.com,
honggiyeong7@gmail.com, *justinshcho@gmail.com

Development of Osteoarthritis and Osteoporosis Diagnosis Prediction Model for Women based on Artificial Intelligence Algorithms Using Health Survey Data

Doyoon Lee¹, Jeongeun Kim², Hwi Joo Park³, Honggi Joung⁴, and Seokheon Cho*
Keimyung University¹, Hannam University², Yonsei University³,
Kumoh National Institute of Technology⁴, *University of California, San Diego (UCSD)

요약

Although osteoporosis and osteoarthritis have different symptoms, there is the common feature that both have high prevalence rate among adult women. However, it is challenging to receive a cost-effective and consistent diagnosis for bone-related diseases, since it is expensive to take MRI or CT examinations of osteoporosis and the measurement instruments for osteoarthritis provide divergent criteria for bone density. In this study, we propose a predictive model for diagnosing osteoarthritis and osteoporosis in women based on Artificial Intelligence algorithms using health survey data. Three Artificial Intelligence algorithms, such as Logistic Regression, Random Forest Classifier, and eXtreme Gradient Boosting machine, are considered for our provided prediction models. Because the health survey data we used is imbalanced, under-sampling technique was applied to improve the model's performance. In addition, various feature sets were selected to reduce the dimensionality of independent variables. We identified that the prediction model based on the eXtreme Gradient Boosting machine algorithm, which uses the dataset applied by under-sampling method, exhibits the best performance.

I. 서론

골다공증은 골밀도의 감소로 인해 골 강도가 약해지면서 가벼운 충격에도 골절이 발생하는 질환이다. 이에 동반되는 골절 및 합병증으로 인한 건강 악화는 개인 및 국가의 경제적 손실을 야기할 수 있는 심각한 문제이다 [1]. 그러나 골다공증 진단을 위한 골 밀도 측정 기기의 종류는 연구기관마다 다르다. 또한 같은 측정 기기이어도 기관마다 상이한 기준을 사용하고 있다는 점 때문에 골다공증 측정에 대한 타당성에 의문이 제기되어 관련된 연구가 진행되어 왔다 [2]. 같은 골 관련 질환 범주 아래 다른 증상을 수반하는 질환인 골관절염의 경우 관절 주변과 연골 하부의 퇴행성 변화가 진행됨에 따라 관절에 염증이 발생하는 질환이다 [3]. 골다공증과 골관절염은 증상은 다르지만 성인 여성에게 유병률이 높은 골 관련 질환이라는 점에서 공통점이 존재한다. 하지만, 골다공증의 진단의 경우 앞서 언급한 의료기기마다 상이한 기준을 갖는다는 점과 골관절염의 경우 정확한 판단을 도출하기 위해서 값비싼 MRI 또는 CT 검사가 필요하다는 점은 골 관련 질환의 진단을 어렵게 만드는 원인이다. 따라서, 본 연구에서는 의료기기를 통한 골 관련 질환 진단이 아닌 여성들의 생활 방식 데이터를 활용하여 인공지능 알고리즘 기반 골관절염 및 골다공

증 진단 예측 모델을 제시하고자 한다.

Y. Wang *et al.* 의 연구에 의하면, 생활 습관 데이터와 진단 이력 데이터의 사용은 골다공증 예측을 하는 데에 적합한 것을 알 수 있다 [4]. 통계적 변수분석 기법인 t-test 를 활용해 수치 데이터 중 골다공증과 정상군의 차이를 보이는 유의미한 변수를 선택하여 Artificial Neural Network (ANN), Deep Belief Network (DBN), Support Vector Machine (SVM) 및 Genetic Algorithm-Decision Tree (GA-DT) 알고리즘들을 사용한 골다공증 예측 모델을 제안하였다. 특히, ANN 모델의 성능은 Area Under the Curve (AUC) 0.762와 정확도 0.728로 가장 높았다. X. Wu *et al.* 의 골다공증 연구는 생활 데이터뿐만 아니라 유전적 데이터 및 영양데이터를 사용하여 특정 지역 (한국 안산/안성) 인구를 대상으로 연구를 진행하였다 [5]. Random grid search를 사용하여 골다공증 환자군과 연관성이 높은 변수 조합으로 최적화된 골다공증 진단 예측 모델을 제시하였다. 이러한 선행연구를 바탕으로 생활 습관 데이터, 진단 이력 데이터, 유전정보 데이터 그리고 영양데이터를 통해 골다공증에 대한 진단이 가능하다는 사실을 알게 되었다. 그러나 골관절염 역시 이러한 정보를 바탕으로 예측이 가능하다는 연구를 찾긴 어려웠다. 또한, 일반인들은 진단 이력과 유전정보 데이터에 접근하기에 어렵다는

문제점이 존재한다. 따라서 본 연구에서는 골 관련 질환 발병 비율이 높은 집단인 성인 여성을 대상으로 일반인들도 쉽게 대답할 수 있는 설문 변수를 이용하여 골관절염 및 골다공증의 예측 모델을 제시하고자 한다.

본 논문의 구성은 다음과 같다. 제 II장에서는 원본 데이터 세트 및 전처리 과정을 설명한다. 제 III장에서는 골관절염 및 골다공증 진단 예측 모델을 위해 사용된 알고리즘과 성능 평가 지표를 제시한다. 제 IV장에서는 골관절염 진단 예측 모델 분석을 제시하며 제 V장에서는 골다공증 진단 예측 모델 분석을 제시하려 한다. 마지막으로 제 VI장에서는 본 연구의 결론과 후속연구를 제시하며 마무리하고자 한다.

II. 데이터 세트 설명 및 전처리 과정

2.1 원본 데이터 세트 설명

본 연구에서는 대한민국 질병관리청의 국민건강영양조사 (Korea National Health & Nutrition Examination Survey: KNHANES)에서 제공하는 2021년도 기본 DB (fundamental DB)인 건강설문조사 (health survey) 및 영양 조사 (nutrition survey) 데이터를 이용하였다 [6]. 본 데이터는 설문조사 응답 자료와 신체 검사를 통한 측정자료로 구성되어 있다. 변수는 총 864개이며 설문 대상자는 총 7,090명에 해당한다. 골관절염과 골다공증 진단에 대한 그룹 분류는 동일한 데이터를 활용한 H. Y. Lim의 연구를 바탕으로 진행하였다 [7]. 의사로부터 각 질병을 진단받은 그룹과 진단받지 않은 그룹을 각각 환자군과 정상군으로 분류하였다. 이로써, 전체 골관절염 환자군은 649명과 정상군 4,696명으로 나누어졌고 나머지 1,745명은 비해당/모름/결측에 해당되었다. 또한 골다공증은 환자군은 455명과 정상군 4889명, 그리고 비해당/모름/결측은 1,746명으로 구성되었다.

2.2 원본 데이터에 대한 전처리 과정

본 연구는 성인 여성을 대상으로 한 골관절염 및 골다공증 진단 예측 모델 개발을 제시한다. 따라서 원본 데이터 세트에서 남성에 해당하거나 만 18세 이하의 데이터 샘플들은 제외하였다. 또한 본 연구에서 설정한 주요 변수는 일반인이 쉽게 대답 가능한 설문 변수이다. 따라서 혈액 검사, 소변 검사, 안압 검사 등과 같은 정밀 의료 검사를 필요로 하는 설문 변수들은 제외하였다. 설문 문항에 있어서 모름 또는 무응답으로 답을 한 케이스의 경우는 결측값으로 분류하였고, 결측값이 10% 이상 존재하는 변수들은 자료에서 제외하였다. 10% 미만의 결측값이 존재하는 변수에 대해서는 다음과 같은 기준을 적용하였다. 명목형 변수 (nominal variable)들의 경우 최빈값 (mode) 그리고 순서형 변수 (ordinal variable)들에는 중위값 (median)을 대치하였다. 또한, 일주일 내 고강도 운동시간 (시간), 일주일 내 고강도 운동시간 (분) 등과 같이 중복되는 변수는 추후 진단 대상자의 대답의 용이성을 위해 (시간)으로 통일하였다. 관절염 여부와 류마티스 관절염 여부 등의 변수들은 골다공증 및 골관절염과 밀접하게 연관되어 있기 때문에 진단 예측 모델 성능을 영향을 줄 수 있다는 판단하에 고려하는 독립변수 목록에서 제외하였다.

이러한 기준을 통해 전처리 과정을 거쳐 생성된 데이터 세트는 167개의 변수를 포함하며 골관절염 진단 데이터 세트와 골다공증 진단 데이터 세트로 분류하였다. 각 데이터 세트의 샘플 수는 2,832명과 2,991명이 선택되었으며 그림 1은 본 연구에서 사용하는 데이터 세트에서 골관절염 및 골다공증 환자군과 정상군 비율을 보여주고 있다. 골관절염의 경우에는 486명 (17.2%)의 환자군과 2,346명 (82.8%)의 정상군으로 구성되었으며 골다공증은 436명 (14.6%)의 환자군과 2,555명 (85.4%)의 정상군으로 구성되었다. 이러한 수치는 고려하고 있는 성인 여성의 골관절염과 골다공증 진단 데이터의 불균형이 존재하는 것이 확인될 수 있다.

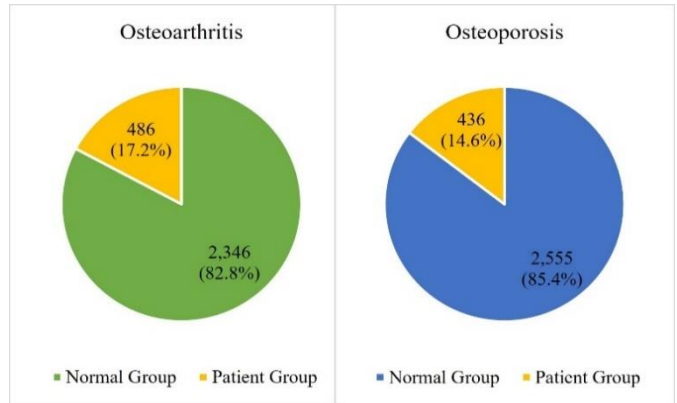


그림 1. 2개 종속변수 구성 비율 (좌측: Osteoarthritis, 우측: Osteoporosis)

데이터의 불균형은 진단 예측 모델의 성능을 저해하는 요인 중의 하나가 될 수 있다. 이에 본 연구에서는 다수 클래스 (majority class)에 속한 데이터 샘플들을 랜덤하게 선택하여 소수 클래스 (minority class) 샘플 개수와 동일하게 맞추는 언더샘플링 (under-sampling) 기법을 사용하였다. 이로써 골관절염과 골다공증 진단 예측을 위해서 환자군 486명과 랜덤하게 선택한 정상군 486명을 포함한 972명 골관절염 데이터 세트, 436명의 환자군과 랜덤하게 선택한 436명의 정상군을 포함한 872명의 골다공증 데이터 세트를 생성하였다.

본 연구에서 사용된 독립 변수는 크게 3가지 요인으로 분류된다. 첫 번째는 사회 인구학적 요인으로 나이, 직업, 소득분위 및 가구 단위 등이 해당한다. 두 번째로, 생활 습관 요인으로 일주일간 고강도 운동 반복 시간, 흡연 여부 그리고 수면 시간 등이 해당한다. 마지막으로 여성 건강 요인으로는 임신 횟수와 모유 수유 횟수 등의 변수가 해당한다. 종속변수는 위에서 설명한 골관절염과 골다공증의 의사 진단 여부를 사용하였다.

또한 선별 기준을 통하여 생성한 167개의 변수를 모두 사용하는 것이 아닌 변수들의 최적 선택 조합 탐색을 위해 Genetic Algorithm (GA)을 사용하였다. GA를 통하여 골관절염은 80개의 독립변수들의 조합을 선택하였으며 골다공증의 경우 84개의 독립변수 조합을 선택하였다. 또한, GA 사용 유무에 따라 생성되는 2개의 다른 데이터 세트를 이용하여 진단 예측 모델 성능을 비교하였다. 고려하는 2개의 데이터 세트는 모든 독립변수들을 포함한 Constructed

Feature Dataset (CFD)과 GA를 사용하여 선택한 독립변수 들만을 포함하는 Selected Feature Dataset (SFD)이다.

III. 알고리즘 및 성능 평가 지표

본 연구에서는 Logistic Regression (LR), Random Forest Classifier (RFC), 그리고 eXtreme Gradient Boosting machine (XGB), 총 3개의 알고리즘들을 사용하여 골관절염 및 골다공증 진단 예측 모델을 개발하였다. LR은 샘플이 특정 클래스에 속할 확률을 선형적인 모델을 이용해 추정하고 입력 특성의 가중치 합을 계산하여 결과 값의 로지스틱을 출력한다. RFC는 배깅 (bagging) 방법을 적용한 결정 트리(Decision Tree)의 앙상블(Ensemble) 모델이다. 트리의 노드를 분할할 때 전체 변수 중 최선의 변수 조합을 찾는 대신 무작위로 선택한 변수 조합 중에서 최적의 변수 조합을 찾는 식으로 무작위성을 주입하는 방식을 통하여 결정 트리를 다양하게 만들고 편향을 손해를 보는 대신 분산을 낮춰 전체적으로 안정화된 모델을 만들어낸다. XGB는 앙상블에 이전까지의 오차를 보정하도록 예측기를 순차적으로 추가하여 이전 예측기가 만든 잔여 오차에 새로운 예측기를 학습시키는 방법이다. 또한 진단 예측 모델들에 있어서 샘플링 방법으로 인한 성능 편향을 줄이기 위해 5겹 교차검증 (K-fold cross validation)을 적용하였다.

진단 예측 모델의 성능 평가에는 Receiver Operating Characteristic (ROC)의 면적의 적분 값인 Area Under the Curve (AUC)와 재현율 (recall), 그리고 F1-score을 사용하였다. AUC는 0에서 1사이의 값을 가지며 정상군과 환자군에 대한 예측 정확도가 높을수록 1에 가까운 값을 갖는다. 재현율 (recall)과 F1-score는 위음성의 판별에 용이한 평가 지표이다. 위음성의 발생은 실제 환자군을 정상군으로 예측하는 오류가 발생할 수 있고 이러한 진단은 질환 대상자에게 치명적일 수 있다. 따라서 recall을 통해 진단 대상자가 실제로 환자군인 경우 환자군으로 예측하는 비율을 확인하였으며 정밀도 (precision)와 재현율의 조화평균인 F1-score을 통해 위양성과 위음성의 예측 비율을 확인하였다. Recall과 F1-score 모두 1에 가까울수록 모델 성능이 우수함을 의미한다.

IV. 골관절염 진단 예측 모델 분석

그림 2는 골관절염 진단 예측 모델의 ROC-AUC 성능 비교를 제시한다. 샘플링 기법을 적용하지 않은 경우 (no sampling)의 CFD에서 RFC 알고리즘 기반 모델이 0.868로 가장 높은 AUC를 보여주었으며, SFD에서는 LR 알고리즘 기반 모델이 0.834로 가장 높았다. 언더샘플링 기법이 적용된 CFD에선 XGB가 0.864로 가장 높았고 SFD의 경우 LR이 0.862로 가장 높았다.

그림 3은 샘플링 방법 및 CFD와 SFD의 데이터 세트에 따른 골관절염 진단 예측 모델의 recall 성능을 제시한다. No sampling 데이터 세트와 언더샘플링 기법이 적용된 데이터 세트의 recall의 차이가 크다는 것을 확인할 수 있다. 낮은 recall값을 가지는 예측 모델은 실제로 골관절염 환자를 정확히 예측하지 못하는, 즉 위음성률이

높은 모델이라 판단할 수 있다. 한편 언더샘플링 기법을 적용한 경우에 있어서, CFD를 사용한 XGB 알고리즘 기반 모델이 가장 높은 0.914의 recall값을 가지는 것을 확인할 수 있었다.




그림 2. 골관절염 진단 예측 모델 AUC 분석




그림 3. 골관절염 진단 예측 모델 recall 분석

그림 4는 골관절염 진단 예측 모델의 F1-score값을 보여준다. No sampling 데이터 세트에서 CFD와 SFD를 사용하는 모든 예측 모델들에 대해서 매우 낮은 F1-score값을 가짐을 확인할 수 있다. 이와는 달리, 언더샘플링 기법을 적용함으로써 F1-score값이 크게 상승하였다. 특히, CFD를 사용한 XGB 알고리즘 기반 모델이 0.795의 F1-score값을 가짐으로써 가장 우수한 성능을 보였다.

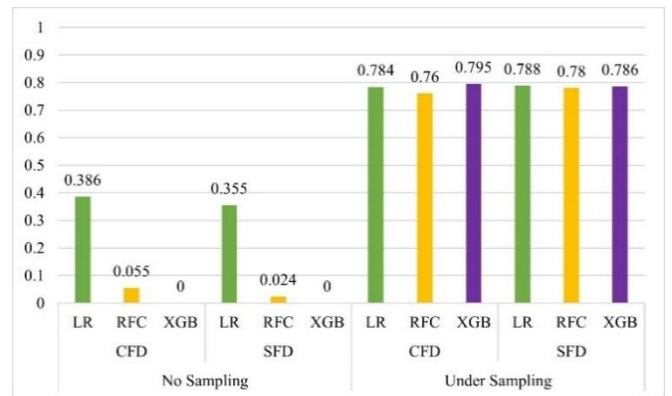


그림 4 골관절염 진단 예측 모델 F1-score 분석

그림 1에서 확인할 수 있듯이 종속변수인 골관절염의 심한 데이터 불균형 때문에 샘플링 기법을 적용하지 않은 데이터 세트의 경우 모든 예측 모델들의 성능이 좋지 못함을 확인할 수 있었다. 그림 2, 그림 3과 그림 4의 결과들을 종합하면, no sampling 데이터 세트들에 대한 골관절염 진단 예측 모델들의 AUC값은 준수했지만, recall값 그리고 F1-score값이 매우 낮았다. 이러한 결과는 모델이 훈련 데이터에서 정상군의 데이터를 과도하게 학습하여 테스트 데이터에서 환자군의 데이터마저 정상군으로 분류하여 발생한 오류라고 예상할 수 있다. 즉, 본 연구에서 관심이 있는 실제로 골관절염을 앓고 있는 여성들에 대해서 정상군으로 예측하는 경우가 무척 많다는 것이다. 따라서 골관절염 진단 예측을 위해서는 언더샘플링 기법 적용이 필수적인 것으로 보인다. 또한, 언더샘플링 기법을 적용하였을 때 특히 CFD를 사용하는 XGB 알고리즘 기반 모델에서 가장 높은 ROC-AUC 값, recall 값 그리고 F1-score 값을 보였다.

V. 골다공증 진단 예측 모델 분석

그림 5는 골다공증 진단 예측 모델의 ROC-AUC 성능을 보여주고 있다. 샘플링 기법을 사용하지 않은 (no sampling) CFD에선 LR 알고리즘 기반 모델이 0.868로 가장 높은 AUC를 보여주었으며, SFD에서는 XGB 알고리즘 기반 모델이 0.889로 가장 높았다. 언더샘플링 기법을 사용한 CFD에선 LR 알고리즘 기반 모델이 0.883으로 가장 높았고 SFD의 경우 RFC 알고리즘 기반 모델이 0.883로 가장 높았다.




그림 5. 골다공증 진단 예측 모델 AUC 분석

그림 6은 샘플링 방법 및 CFD와 SFD의 데이터 세트에 따른 골다공증 진단 예측 모델의 recall 성능을 보여주고 있다. No sampling 데이터 세트와 언더샘플링 기법이 적용된 데이터 세트의 recall의 차이가 크다는 것을 확인할 수 있다. 높은 recall값을 가지는 예측 모델은 실제 골다공증 환자를 올바르게 예측하는 경우가 많다는 것을 의미한다. 또한, 언더샘플링 기법을 적용한 경우에 있어서, SFD를 사용한 XGB 알고리즘 기반 모델이 가장 높은 0.872의 recall값을 가지는 것을 확인할 수 있다.

그림 7은 골다공증 진단 예측 모델의 F1-score값을 보여준다. No sampling을 한 순수한 CFD와 SFD를 사용하는

모든 예측 모델들에 대해서 매우 낮은 F1-score값을 확인할 수 있다. 이와는 달리, 언더샘플링 기법을 적용함으로써 F1-score값이 크게 상승하였다. 특히, SFD를 사용한 XGB 알고리즘 기반 모델이 0.812의 F1-score값을 가짐으로써 가장 우수한 성능을 보였다.




그림 6. 골다공증 진단 예측 모델 recall 분석




그림 7. 골다공증 진단 예측 모델 F1-score 분석

골관절염과 마찬가지로, 종속변수인 골다공증도 불균형 데이터 특징을 가지고 있기 때문에, 샘플링 기법을 적용하지 않은 데이터 세트들에 대한 예측 모델들의 AUC-ROC 값은 준수했지만 recall 값과 F1-score 값이 극도로 좋지 못했다. 이러한 결과는 훈련 데이터에서 정상군에 대한 데이터를 과도하게 학습하여 테스트 데이터에서 대부분의 골다공증 환자군들에 대하여 정상군으로 잘못 분류하였기 때문에 발생하는 것이다. 즉, 실제로 골다공증의 환자군에 속한 여성들에 대해서 골다공증 증상이 없다고 틀리게 예측하는 경우가 무척 많다는 것이다. 따라서 골다공증 진단 예측 모델 역시 성능을 향상시키기 위해서는 언더샘플링 기법 적용이 필수적이다. 게다가, 언더샘플링 기법을 적용하였을 때 SFD를 사용하는 XGB 알고리즘 기반 모델이 가장 높은 recall 값과 F1-score값을 가지는 것으로 확인하였을 때 골다공증 진단 예측 모델 개발 역시 XGB 알고리즘을 기반으로 하는 것이 적절한 방안으로 보인다. 골다공증의 진단의 경우 앞서 언급한 의료기기마다 상이한 기준을 갖는다는 점과 골관절염의 경우 정확한 판단을 도출하기 위해서 값비싼 MRI 또는 CT 검사가 필요하다는 점은 골 관련 질환의 진단을 어렵게 만드는 원인이다.

VI. 결론

의료기기마다 상이한 기준을 갖는 골 밀도 측정과 정확한 진단을 위해 이용되는 값비싼 MRI 또는 CT 검사는 골 관련 질환에 대한 진단을 어렵게 만드는 원인이었다. 이에 본 연구에서는 이러한 문제들을 해소하기 위해 일반인들이 간단하게 대답할 수 있는 건강 설문조사를 통해 수집가능한 데이터를 이용하여 성인 여성을 위한 골관절염 및 골다공증의 진단 예측 모델을 제안하였다. 골관절염과 골다공증 모두 정상군과 환자군 사이의 데이터의 불균형이 존재했다. 따라서 이러한 불균형을 해소하기 위해 언더샘플링 (under-sampling) 기법을 적용하였다. 또한 최적의 독립변수들을 선택하기 위해 Genetic Algorithm를 사용하였다. 골관절염 및 골다공증 진단 예측 모델을 분석한 결과, 데이터 불균형을 해소하기 위해 사용하는 언더샘플링 기법이 진단 예측 모형의 성능 향상을 위해 필수적이라는 것과 eXtreme Gradient Boosting Machine 알고리즘 기반 진단 예측 모델이 가장 우수한 성능을 보임을 알게 되었다.

본 연구는 여성의 골관절염 및 골다공증 진단만을 예측하는 모델을 제시하였다. 따라서 향후 연구로서 남성을 위한 진단 예측 모델 개발과 성별에 따른 골관절염 및 골다공증의 주요 발생 요인에 대한 분석이 필요하다.

ACKNOWLEDGMENT

Following are results of a study on the "Leaders in INdustry-university Cooperation 3.0" Project, supported by the Ministry of Education and National Research Foundation of Korea.

This research was supported by the MSIT (Ministry of Science, ICT), Korea, under the National Program for Excellence in SW, supervised by the IITP (Institute of Information & communications Technology Planning & Evaluation) in 2024 (2023-0-00054).

참 고 문 헌

- [1] Hyuk Joon Kim and Hye Young Kim, "Factors Influencing the Health-Related Quality of Life of Postmenopausal Women with Diabetes and Osteoporosis: A Secondary Analysis of the Seventh Korea National Health and Nutrition Examination Survey (2016-2018)," Korean Journal of Women Health Nursing, vol. 28, no. 2, pp. 112-122, Jun. 2022.
- [2] Woo Nam Moon, Han Jin Oh, and Seung Woo Suh, "Differences in Bone Mineral Density by Using Different Densitometers or by Measuring Different Sites of Spine in Osteoporotic Vertebral Fractures," Journal of the Korean Orthopedic Association, vol. 34, no. 6, pp. 1153-1157, 1999.
- [3] Sook Young Kim and Eun Young Jeon, "Influencing Factors on Osteoarthritis in Korean," Korean Journal of Rehabilitation Nursing, vol. 14 no. 2, pp. 111-117, Dec. 2011.
- [4] Yuqi Wang, Liangxu Wang, Yanli Sun, Miao Wu, Yingjie Ma, Lingping Yang, Chun Meng, Li Zhong, Mohammad Arman

Hossain, and Bin Peng, "Prediction Model for the Risk of Osteoporosis Incorporating Factors of Disease History and Living Habits in Physical Examination of Population in Chongqing, Southwest China: Based on Artificial Neural Network," BioMed Central Public Health, vol. 21, no. 1, pp. 1-10, May. 2021.

- [5] Xuangao Wu and Sun Min Park, "A Prediction Model for Osteoporosis Risk Using a Machine-Learning Approach and Its Validation in a Large Cohort," Journal of Korean Medical Science, vol. 38, no. 21, pp. 1-21, 2023.
- [6] Korean National Health and Nutrition Examination Survey, "Fundamental DB: Health Survey & Nutrition Survey," 2021, Available: https://knhanes.kdca.go.kr/knhanes/sub03/sub03_02_05.do
- [7] Hwa Young Lim, "Prediction of Myocardial Infarction/Angina and Selection of Major Risk Factors Using Machine Learning," Journal of The Korean Data Analysis Society, vol. 20, no. 2, pp. 647-656, 2018.