

<http://dx.doi.org/10.17703/JCCT.2024.10.6.677>

JCCT 2024-11-83

## 다양한 노인 생활 지표를 활용한 기계학습 기반 노인 건강 요인 예측

### Machine Learning-based Elderly Health Prediction with Various Factors of Elderly

아잠\*, 이재형\*\*, 윤유림\*\*\*

Rakhmatov Azam\*, Jaehyeong Lee\*\*, Yourim Yoon\*\*\*

**요약** 노인들의 삶의 질, 약력, 경제활동 등 다양한 지표들은 그들의 종합적인 복지와 건강 상태를 반영한다. 이러한 정보를 활용한 종합적인 평가는 노인의 건강 상태를 예측하는 데 유용하다. 본 연구에서는 지역사회 거주 노인의 건강을 예측하는 종합적인 지표에 대해 기계학습 기반 예측 모델을 적용하고 비교하는 것을 목표로 한다. 고령화연구패널에서 제공하는 4652명의 데이터를 활용하여 예측 변수에 맞게 다양한 머신러닝 기법을 사용하여 각 모델을 평가하였다. 그 결과, 약력 예측에는 LightGBM Regression 모형이 RMSE 5.082, MSE 25.83로 가장 우수한 성능을 보였으며, 현재 건강 상태 예측에서는 Gradient Boosting이 RMSE 0.588과 R-Square 0.456로 가장 좋은 성과를 보였다. 한편 고령층의 경제활동 참여에 대한 예측 결과는 Random Forest 모델이 우수함을 드러냈다. 이러한 기계학습 기반 예측 모델은 노인의 건강 상태 평가와 경제활동 참여 예측에 대한 방향성을 제시하며, 종합적인 예측을 위해 다양한 방법론을 수행하여야 함을 시사한다.

**주요어** : 고령층 건강 예측, 고령층 경제활동, 기계학습, 데이터 전처리

**Abstract** The quality of life, frailty, economic activity, and other indicators are crucial for assessing older adults' overall well-being and health status. A comprehensive evaluation using this information helps predict the health status of older adults. This study aims to apply and compare machine learning-based prediction models for comprehensive health indicators of community-dwelling older adults. Utilizing data from 4,652 individuals provided by the Aging Research Panel, we assessed various machine learning techniques to fit the predictor variables. Our findings reveal that the LightGBM Regression model performed the best, with an RMSE of 5.082 and an MSE of 25.83. The Gradient Boosting model best predicted current health status, with an RMSE of 0.588 and an R-Square of 0.456. Additionally, the Random Forest model showed strong performance in predicting economic activity participation among older adults. These machine learning-based models offer valuable insights for evaluating health status and predicting economic activity participation, highlighting the importance of employing diverse methodologies for comprehensive predictions.

**Key words** :Elderly Health Prediction, Elderly Economic Ability, Machine Learning, Data Preprocessing

\*준회원, 가천대학교 IT융합공학과(컴퓨터공학전공) 석사과정Received: August 20, 2024 / Revised: September 25, 2024

(제1저자)

Accepted: November 10, 2024

\*\*준회원, 가천대학교 IT융합공학과(컴퓨터공학전공) 박사과정\*\*\*Corresponding Author: yryoon@gachon.ac.kr

(참여저자)

Dept. of Computer Engineering, Gachon University, Korea

\*\*\*정회원, 가천대학교 컴퓨터공학부(컴퓨터공학전공) 부교수

(교신저자)

접수일: 2024년 8월 20일, 수정완료일: 2024년 9월 25일

게재확정일: 2024년 11월 10일

## I. 서 론

대한민국의 인구 고령화는 어느 때보다 빠르게 진행되고 있고, 인구 고령화의 세계화 추세에 따른 다른 나라와의 고령화 속도에 비추어 보아도 상대적으로 그 속도가 매우 빠르다. 이러한 급속한 인구 고령화는 사회 전체에서 각 연령 분포 비율이 급격하게 달라진다는 점에서 자원의 분배와 부양에 대한 미시적 측면의 가족세대 간, 그리고 거시적 측면의 사회 코호트 간의 다이내믹이라는 이슈를 내포한다. 상대적 측면 아니라, 연령에 따른 고령인구의 절대적 증가는, 양적인 측면에서 유례 없이 확장된 노년기를 질적인 측면에서 어떻게 담보할 것인지 라는 당면과제에 답해야 하는 문제이기도 하다 [1].

인구 고령화와 관련한 핵심적인 사회적 이슈 중 하나는 노년기 건강이다 [2]. 노년기는 생애 발달 주기에서 건강 관련 의료 비지출이 가장 높은 시기인 동시에, 이러한 노년기가 평균수명의 증가로 인해 더욱 길어지고 있기 때문이다. 고령인구의 증가를 거시적 측면에서 사회적 부담의 문제로 논의하거나 미시적 측면에서 개인은 과연 늘어난 수명에 얼마나 준비되었는가에 대한 논의가 활발한 것도 바로 이 때문이다. 따라서 현재 대한민국 노인들의 전반적인 건강 상태와, 이 변화에 영향을 미치는 개인, 노인 건강에 영향을 끼치는 요소들은 사회적, 경제적, 그리고 의료 체계의 다양한 측면에서 중요성을 지닌다. 건강한 노인은 사회 참여를 통해 사회 안녕감을 증진시키고, 가족과 지역사회에 긍정적인 영향을 미친다. 이는 노동 시장에서의 지속적 참여로 경제적 안정성을 유지하고 국가 전반에 이로운 영향을 미친다. 건강한 노인은 가족 구조에 긍정적인 영향을 미치며, 가족들은 도움을 받는 것이 아니라 동반자로서 노인과 소통하며 지낼 수 있다 [3]. 또한, 건강한 노인은 의료 비용을 감소시키고 의료 시스템에 대한 부담을 경감시킨다. 마지막으로, 건강한 노인은 자신의 삶을 즐기며 긍정적인 삶을 유지할 수 있다. 따라서 노인 건강은 개인 차원에서만 아니라 사회적, 경제적, 의료 체계의 측면에서도 매우 중요하며, 건강한 라이프스타일과 적절한 의료 서비스가 필수적이다 [4].

하지만 이런 지표들을 예측하는 것은 쉽지 않은 문제로 꼽힌다. 예를 들어, 한 노인에게 여러 가지 질환이

같이 존재하고 질병에 따른 증상 발현이 일반적이지 않은 점을 꼽을 수 있다. 일반적으로 노인들에게 발생하는 질환들은 한 가지 원인으로 여러 장기에 질환이 발생하는 것이 보통이다. 일반적으로는 고혈압에 의해서 신경화증, 심부전, 뇌출혈 등이 발생되어 3가지 장기에 질환이 있을 수 있다. 그러나 노인의 경우에는 여러 가지 원인으로 여러 장기에 질환이 동시다발적으로 발현되어 있는 경우가 대부분이다. 예를 들어 고혈압에 의해서 이상과 같은 3장기에 질환이 있고 동맥경화에 의해서 혈관성 치매가 발생 되고 골다공증에 의해서 척추의 압박골절이 있고 백내장과 폐섬유증이 있는 경우에는 심장, 신장, 뇌, 골, 안구, 폐 등에 질환이 공존하고 있다. 이러한 경우 6개의 장기에 질환이 있으나 이는 다양한 원인에 의해서 발생 된 질환이므로 인과관계가 없는 경우가 많다. 일반적으로 발열, 빈혈, 심잡음이 있는 환자는 감염성 심내막염을 의심하지만 노인에는 감기에 의한 발열, 만성질환에 의한 빈혈, 동맥노화에 의한 기능성 잡음 때문에 이상이 없다고 진단하는 경우도 있다 [5]. 또한 노인의 건강을 예측하는 데는 단순히 질병의 유무만을 고려하는 것이 아니라 다양한 요인들이 복합적으로 작용한다는 점에서 어려움이 있다. 건강 문제 외에도 경제적, 사회적 요인들이 노인의 건강에 중요한 영향을 미친다. 예를 들어, 경제적 어려움은 적절한 의료 서비스를 받지 못하게 하여 건강악화를 초래할 수 있다. 사회적 고립 역시 정신적, 신체적 건강에 부정적인 영향을 미칠 수 있다. 가족이나 친구와의 사회적 네트워크가 부족한 노인은 우울증, 불안증과 같은 정신 건강 문제에 더 취약하다. 이러한 요인들은 직접적인 건강 문제와는 다르지만, 결과적으로 노인의 전반적인 건강상태에 큰 영향을 미친다.

따라서 본 연구에서는 설문 조사 데이터를 기반으로 노인 건강과 관련된 다양한 예측을 하고자 한다. 구체적으로는 한국고령화중단연구(KLoSA) [6]를 활용하여 근력, 치매, 삶의 질 등 노인 건강과 관련된 다양한 지표들을 기계학습을 통해 예측하고자 하며, 이를 통해 경제적 요인과 생활적 여건 등 다양한 측면을 고려하여 노인 건강을 이해하고 예측하는 데 기여하고자 한다. 또한, 단순히 하나의 기계학습 알고리즘만을 사용하는 것이 아니라 여러 알고리즘을 활용하여 예측 모델을 구축하고 그 성능을 비교함으로써 최적의 모델을 찾아내고 제안해보고자 한다.

## II. 관련 연구

기존의 연구들은 노인 생활과 관련이 있는 여러 지표들이 노인 건강에 직간접적인 영향을 끼친다고 설명한다. 그 예로, 사회 참여와 건강 간의 밀접한 연관성을 확인한 연구들도 발표되었다. [7]의 연구는 적극적인 사회 참여는 우울감 감소와 행복감 증진과 같은 정신적인 측면에 긍정적인 영향을 미친다고 설명한다. 또한, 높은 수준의 사회 참여가 신체적, 주관적 건강과 유의한 관련이 있음이 입증한 연구도 발표된 바 있다 [8]. 또한 회 참여가 낮은 사망률과 관련이 있다는 결과도 보고된 바 있다 [9, 10]. 이들 연구에서는 건강의 다양한 측면과 밀접한 관련을 갖는 사회 참여의 다양성이 논의되었다. 예를 들어, 정기적인 친구나 이웃과의 모임, 봉사 활동, 종교적 활동, 여가 활동, 그리고 가족이나 친지 관계에서의 지원 등이 논의 대상에 포함된다. 사회 참여의 다양한 형태가 건강에 미치는 정적인 효과를 논의가 증가하는 만큼, 각각의 활동이 건강의 어떤 측면에 영향을 미치는지, 그 효과가 어떻게 다른지를 고려하는 것이 중요하다. 사회 참여의 다양한 형태에 대해 구체적으로 살펴보면, 종교 활동은 주로 정신 건강 및 행복감에 긍정적인 영향을 미친다고 보고되어 왔다 [11, 12, 13]. 다른 대표적인 건강과 관련된 사회 참여 유형으로는 봉사 활동이 제시되기도 한다 [14, 15]. 가족 및 친지 관계에서는 양육과 같은 활동이 신체적 건강에 영향을 미치는 것으로 보고되지만, 이와 관련된 연구 결과는 혼재되어 있다. 일부 연구에서는 긍정적인 효과를 보고한 반면, 다른 연구에서는 둘 사이의 관련성이 없다는 결과가 있다 [16].

사회 참여의 형태는 다양하며, 이는 주관적인 건강에 미치는 영향의 크기와 방향도 다양하게 나타난다. 해외 연구에서는 봉사 활동, 종교 활동, 여가 활동 등 다양한 형태의 사회 참여와 건강 사이의 연관성이 탐구되었지만, 국내 연구에서는 주로 여가 활동에 집중되었으며 [17, 18], 종교 활동이나 봉사 활동과 같은 연구는 드물었다. 한국의 노인들은 봉사 활동이나 친목회와 같은 사회 참여보다는 상대적으로 덜 참여하며, 이로 인해 해당 분야의 연구 자료가 부족하다는 것이 해당 연구의 난점으로 꼽힌다. 이에 본 연구에서는 다양한 활동 영역을 고려함으로써 여러 지표를 포함하여 이에 대한 예측이 제대로 이루어질 수 있는지 확인해보고자 한다.

## III. 실험 방법

### 1. 데이터셋 준비

분석 과정을 거치기 위해 탐색적 데이터 분석 (EDA, Exploratory Data Analysis)을 실시하여 결측치, 이상치 등을 확인하였다. 그 다음 실험을 위한 한국고용정보원에서 진행한 고령화패널조사(KLoSA) 데이터 [6]를 활용했다. 그 중에서, 2023년 기준 공개된 최신 결과인 2020년에 진행된 8차 KLoSA 조사의 라이트 버전 데이터를 활용했다. 이 데이터는 대한민국 제주도를 제외한 지역에 거주하는 1962년 이전 중고령자 개인을 대상으로 약 10,000명에게서 수집하였다 [21]. 해당 조사의 항목은 표 1로 요약하였다.

표 1. KLoSA의 주요조사 내용

Table 1. Main investigation contents of KLoSA

분류	주요 내용
A. 인구	조사 대상자와 그의 배우자에 대한 개인 정보와 사회적 상태에 관한 자세한 정보를 수집
B. 가족(자녀와 손자녀) & D. 고용	자녀 및 손자녀 정보 수집하고, 고용 형태에 따른 세부 사항 요약하고 있음
Ca. 건강상태	주관적 건강상태, 만성질환 여부, 치료 상황, 일상생활 어려움, 사고 및 부상 경험, 노화 관련 상태, 건강 지표, 건강습관, 우울증 정보 다룸.
E. 소득	근로소득, 연금소득, 사회보장소득 여부와 종류, 기타 수입 및 소득, 지난 1년간 가구 총소득 정보 수집하고 있음
F. 자산	거주주택 정보, 부동산 자산, 금융자산, 비금융자산, 상속/증여를 통한 자산, 부채, 가구의 총자산 정보 수집하고 있음
G. 주관적 기대감	경제적 상황 판단, 유산증여/상속 여부, 근로시간 예상, 생활 수준 변화, 정부 기대감, 삶의 만족도 정보 수집하고 있음

그러나 해당 데이터를 그대로 이용하지 않고, 전처리 과정을 별도로 거쳤다. 우선 원본 데이터에 존재하는 고유 ID, 인터뷰 여부나 날짜와 같은 고유티입자나 기본적인 질문에 대한 항목은 배제했으며, 고용상태에 따라 다른 응답을 유도하는 '고용'과 관련된 항목은 분석에서 제외했다. 건강은 건강 상태에 관한 질문만을 포함하고, 발병 시기 등 시계열 관련 응답을 요구하는 질문들은 분석에서 제외되었다. 인지 능력 역시 대표적인

인지 능력은 다양한 측면에서 이해될 수 있으며, 대표적으로 치매, 지능, ADHD, 언어 능력을 포함한다. 치매는 기억력과 사고력의 저하를 특징으로 하며, 알츠하이머병이 대표적이다. 지능은 학습 능력과 문제 해결 능력을 포함하며, IQ 테스트로 평가된다. ADHD는 주의력 결핍과 과잉 행동을 특징으로 하며, 어린이에게서 집중력 부족과 충동성을 나타낼 수 있다. 언어 능력은 말하기, 듣기, 읽기, 쓰기 능력을 포함하며, 언어 발달 장애가 있는 어린이는 또래보다 말을 늦게 시작할 수 있다. 이러한 인지 능력들은 일상생활, 학습, 사회적 상호작용에 중요한 역할을 한다. 또한, 비슷한 질문이 반복적으로 수집된 경우 (BMI와 체중, 신장) 대표적인 항목만을 활용했다. 그리고 '주관적 일자리 기대감'은 연령에 따라 응답되는 항목으로, 이를 하나의 항목으로 통합하여 처리하였다. 전처리가 끝나고 최종적으로 선택된 변수는 144개 변수로 하였다.

이후 기계학습을 통해 예측하고자 하는 지표를 설정하고 이에 맞게 목표 타겟을 설정하였다. 회귀 문제에서는 전반적인 삶의 질, 약력 지수화, 응답자(본인)의 건강상태, 응답자(본인)의 주관적 건강상태를 타겟값으로 설정하였다. 해당 지표들의 통계적 특징은 표 2을 통해서 정리하였다. 또한 분류 문제를 해결하기 위해서 고령층의 경제활동과 고령층 임금노동 참여를 타겟 변수로 활용하였으며, 타겟 변수들의 구분은 표 3를 통해 확인할 수 있다. 특별히 분류 문제를 위해서는 분류 기준에 따라 인코딩을 다시 실시하였다. 여기서는 현재 활동하지 않는 집단을 1, yes로, 활동 중인 집단을 0, no로 분류했다. 또한, 임금 근로 여부는 취업 상태를 기준으로 확인했다. 고용형태에 대한 응답 중 타인 또는 회사에 고용되어 임금을 받고 일하는 경우를 1로, 그 외의 경우를 0으로 분류했다.

## 2. 분석절차 및 방법

우선 본 연구의 분석은 먼저 데이터 정제 과정을 거쳤다. 머신러닝 모델을 적용하기 위해서 결측치 처리하였다. 두 번째로 머신러닝 기법을 적용하여 예측변수 중 주요 변수를 탐색하기 위해 본 연구에서는 5가지 분석 방법을 선정, 가장 적절한 모델을 탐색하였다. 다섯 개 분석방법으로는 Random Forest, LightGBM, 표 2. 회귀 문제 타겟 변수들의 통계적 특징

Table 2. Statistical Characteristics of Regression Problem Target Variables

Var.	w08G0 30	w08mg rip	w08C 001	w08C152
Description	삶의 질	약력	건강 상태	주관적 건강 상태
Min	0	2.78	1	1
Max	100	50	5	5
Avg	64.21	24.17	3.68	2.95
Sd	15.78	8.3	0.81	0.76
# Data	4652			
Feature	144			

표 3. 분류 문제 타겟 변수들의 통계적 특징

Table 3. Statistical Features of the Classification Problem Target Variables

Var.	경제활동 여부	임금노동 여부
Yes	1788명	809명
No	3929명	913명
# Data	5717	1722
# Feature	144	
# Label	1	

Gradient boosting, XGBoost regression, Decision tree regression 모델을 선정하였다. 머신러닝 방법을 적용하기 위해 자료를 70% 대 30%의 비율로 데이터 세트를 training set와 test set으로 분할하였다. 이때 진단 결과가 훈련 데이터 세트와 테스트 데이터 세트에 고르게 분포되도록 나누었다. 전처리를 진행하고 나서 3256개의 훈련 instance와 1395개의 테스트 instance에서 144개의 특징과 1개의 이전 라벨을 설정하였다. 해당 과정은 그림1로 요약하였다. 그리고 고령층 경제활동과 고령층 임금노동을 예측하기 위한 기계학습 모델은 데이터마이닝 분석 패키지인 WEKA[22]를 사용하였다.

본 연구에서는 이러한 모델들을 일정한 지표에 대해 평가했다. 이 지표들은 평균 제곱 오차(Mean Squared Error, MSE), 제곱근 평균 제곱 오차(Root Mean Squared Error, RMSE), 평균 절대 오차(Mean Absolute Error, MAE) 그리고 R-Square이다.

### 1) MSE(Mean Squared Error)

평균 제곱 오차(Mean Squared Error, MSE)는 실제 값과 예측값 사이의 제곱 차이를 의미한다. 즉, MSE는 최적의 적합선이 데이터 포인트들에 얼마나 가까운지

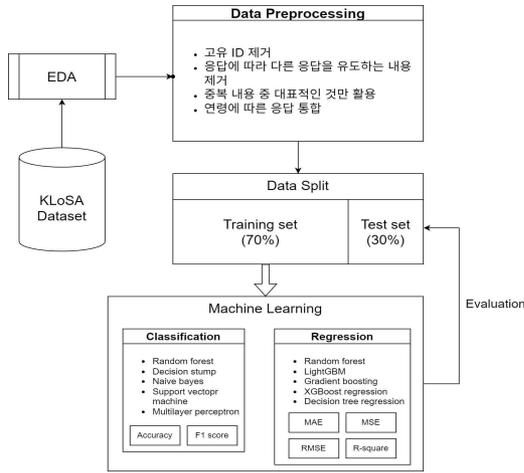


그림 1. 데이터셋 준비 및 전처리 과정에 대한 요약  
 Figure 1. Summary of Dataset Preparation and Preprocessing Process

를 나타낸다. MSE는 항상 양수 값이며, 음수 부호를 제거하기 위해 제곱이 취해진다. MSE가 0에 가까울수록 예측이 더 정확하다. 해당 지표는 (1)에 따라 계산한다. MSE는 모델의 예측값 ( $y_i$ )과 실제값 ( $\hat{y}_i$ )사이의 차이의 제곱을 모두 더한 다음, 데이터 포인트의 총 수( $n$ )로 나눈 값이다. 이는 예측 오류의 제곱 평균을 의미하며, 값이 작을수록 모델의 예측이 실제값에 가깝다는 것을 나타낸다.

$$MSE = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n} \quad (1)$$

### 2) RMSE(Root Mean Square Error)

RMSE는 Root Mean Squared Error의 약자로, 예측 모델의 성능을 평가하는 데 사용된다. 이를 계산하기 위해서는 (2)의 계산식을 따른다.

$n$ 은 예측의 총 개수를 의미한다. 각 예측에 대해 실제값(Observed values)과 예측값(Predicted values) 간의 차이를 구한다. 이 차이를 제곱하여 모든 예측에 대해 합산한다. 그 다음, 이 합계를 예측의 총 개수인  $n$ 으로 나누어 평균을 구한 후 결과에 제곱근 연산을 한다. 이렇게 함으로써 MSE 계산 과정 중 제곱에 의해 생기는 편차를 줄일 수 있게 된다.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (2)$$

### 3) MAE(Mean Absolute Error)

MAE는 예측값과 실제값 간의 차이를 절대값으로 측정하여 평균을 낸 것이다. 이를 계산하기 위해, 먼저 각 예측값과 실제값의 차이를 절대값으로 변환한 후, 그 값들을 모두 더한다. 그런 다음, 그 합을 예측값의 개수로 나누어 평균을 구한다. MAE는 이러한 과정을 통해 예측의 정확성을 평가하며, 값이 작을수록 예측이 실제값에 가까움을 나타낸다. 계산은 (3)을 통해 이루어진다. MSE 계산에서 제곱을 취하지 않고 절대값을 취하는데, 이렇게 함으로써 실제로 관측된 오차만을 반영할 수 있게 된다. 하지만 평균이나 편차 등을 고려하지 않고 오차만 반영한다는 단점도 존재한다.

$$MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad (3)$$

### 4) R-Square 결정 계수

R-제곱( $R^2$ )은 결정 계수라고도 불린다. R-제곱은 종속 변수의 분산 중 독립 변수에 의해 설명되는 비율을 결정한다. R-제곱은 회귀 모델에 대한 적합성(관측값이 예측 값과 얼마나 설명을 잘 하는지에 대한 지표)를 제공한다. R-제곱 점수는 RSS(Residual Sum of Squares)와 TSS(Total Sum of Squares)로 계산하는데, RSS는 모델의 예측과 실제 값 사이의 잔차의 제곱을 합한 값이며, 모델의 적합도를 평가한다. TSS는 종속 변수의 전체 변동을 나타내며, 관측값과 평균값 사이의 제곱을 합한 값이다.

### 5) Confusion Matrix (오차행렬)

Confusion Matrix(혼동 행렬)은 다중 클래스 분류 문제에서 모델의 성능을 평가하는데 지표를 계산하는데 사용된다. 실제 클래스와 예측 클래스 간의 관계를 보여준다. 예측 클래스는 모델이 데이터를 분류할 때 예측한 클래스이고, 실제 클래스는 데이터에 원래 기록되어 있는 실제 클래스를 의미한다. 그림 2는 혼동 행렬을 설명한다.

혼동 행렬을 통해서 기계학습 알고리즘이 분류한 결과에 따라 총 4가지의 지표가 추가로 파생이 되는데,

그 지표들은 다음과 같다:

		Predicted Value	
		Positive	Negative
Actual Value	Positive	TP	FN
	Negative	FP	TN

그림 2. 혼돈 행렬  
Figure 2. Confusion Matrix

- TP (True Positive) - 모델이 올바르게 예측한 긍정적인(positive) 샘플의 수
- FN (False Negative) - 모델이 잘못 예측하여 부정적인(negative) 샘플을 긍정적인 샘플로 예측한 경우의 수
- FP (False Positive) - 모델이 잘못 예측하여 긍정적인 샘플을 부정적인 샘플로 예측한 경우의 수
- TN (True Negative) - 모델이 올바르게 예측한 부정적인 샘플의 수

#### 6) Accuracy(정확도)

정확도(accuracy)는 머신러닝 및 통계에서 모델의 성능을 측정하는 지표 중 하나이다. 정확도는 주어진 데이터셋에서 모델이 올바르게 분류한 샘플의 비율로 정의된다. 직관적으로 계산할 수 있다는 장점이 존재하지만, 단순히 옳게 분류하였는지만 평가하므로 분류기의 성능을 정확히 파악할 수 없다는 단점이 존재한다.

#### 7) F1 Score

F1 Score는 정밀도와 재현율(민감도)을 활용하는 평가용 지수이다. 정밀도와 재현율을 활용함으로써 기계학습 성능을 보다 안정적으로 평가할 수 있게 하는 장점이 있다. (4), (5), (6)의 계산식을 이용하여 계산할 수 있다. 분모에는 정밀도(P)와 재현율(R)을 더한 값을 사용하고, 분자에는 정밀도(P)와 재현율(R)을 곱한 뒤 추가로 2를 곱하여 가중해 준다. 이렇게 함으로써 정밀도와 재현율의 조화평균 값을 고려할 수 있게

된다.

F1 score의 계산 결과는 0에서 1 사이이며, 높을수록 좋은 모델로 간주한다.

$$P = \frac{TP}{TP + FP} \quad (4)$$

$$R = \frac{TP}{TP + FN} \quad (5)$$

$$F1 = \frac{2PR}{P + R} \quad (6)$$

### 3. 기계학습 알고리즘

본 연구에서 분석을 위해 사용한 9가지 머신러닝 알고리즘은 현재 널리 통용되고 있는 Random, Forest, Decision Tree Regressor, XGBoost Regression, LightGBM Regression, Gradient Boosting, Decision Tree, Navie Bayes, SVM(Support vector machine), MLP(Multilayer Perceptron) 모형을 활용하였다.

#### 1) Random Forest

Random Forest는 여러 의사 결정 트리를 결합하여 높은 성능의 모델을 형성하는 앙상블 학습 기법이다. 각 트리는 부트스트랩 샘플링과 랜덤 특성 선택을 통해 독립적으로 학습하며, 최종 예측은 다수결 투표로 이루어진다. 랜덤 포레스트는 다양성을 증가시켜 과적합을 줄이고 안정적인 예측 모델을 형성하는 데 효과적이다 [23].

#### 2) Decision Tree Regressor

Decision Tree Regressor는 입력 변수들의 조합에 따라 연속형 타겟 변수를 예측하는 알고리즘으로, 의사 결정 트리를 사용하여 데이터를 분할하고 각 분할에서 타겟 변수의 값을 예측한다. 질문을 통해 데이터를 분할하고, 새로운 데이터에 대한 예측은 의사 결정 트리를 따라가며 각 변수의 조건을 충족하는 분기로 이동하여 예측 값을 결정한다[24].

#### 3) XGBoost Regression

XGBoost Regression은 앙상블 학습 기법을 활용한 Gradient Boosting 알고리즘이며, 특징 중요도 평가와 자동 가지치기를 통해 높은 예측 성능과 학습 속도를 제공하는 회귀 모델이다 [25].

#### 4) LightGBM Regression

LightGBM Regression은 빠른 속도와 효과적인 대용량 데이터 처리를 갖춘 Gradient Boosting 알고리즘이다. Leaf-Wise 성장 방식, 병렬 및 분산 학습 지원, 메모리 효율적인 특징 등이 특징이며, 범주형과 수치형 특징을 함께 다룰 수 있어 다양한 데이터에 적용 가능하다 [26].

#### 5) Gradient Boosting

Gradient Boosting은 여러 약한 학습기를 순차적으로 결합하여 강력한 예측 모델을 만드는 앙상블 학습 방법이다. 각 단계에서 이전 모델의 오차에 집중하고, 약한 학습기의 조합을 통해 강력한 모델을 형성한다. 과적합에 강한 특성을 가지고 있어 회귀 및 분류 문제에서 효과적으로 사용된다 [27].

#### 6) Decision Tree

의사 결정 트리(Decision Tree)는 데이터를 기반으로 분류나 예측을 수행하는 모델로, 특징들을 트리 구조로 분할하여 각 분할에서 최적의 결정을 내린다. 각 분기점은 데이터의 특징을 기준으로 생성되며, 이를 통해 데이터를 분류하고 예측한다. 해석이 쉽고 설명 가능한 모델이지만, 과적합 문제에 취약할 수 있다 [28].

#### 7) Navie Bayes

나이브 베이즈(Naive Bayes)는 지도 학습 알고리즘 중 하나로, 베이즈 이론을 기반으로 한다. 이 모델은 각 특징(feature)이 서로 독립적이라고 가정하고, 이를 바탕으로 클래스(class)의 확률을 추정한다 [29].

#### 8) SVM(Support vector machine)

서포트 벡터 머신(Support Vector Machine, SVM)은 데이터를 고차원 공간으로 매핑하여 각 클래스를 분리하는 최적의 결정 경계를 찾는 지도 학습 알고리즘으로, 높은 성능과 다양한 커널 함수를 통한 유연성으로 널리 사용된다 [30].

#### 9) MLP(Multilayer Perceptron)

MLP(Multilayer Perceptron)은 여러 개의 은닉층을 가진 인공 신경망으로, 역전파 알고리즘을 사용하여 가중치를 조정하여 학습하는 모델이다. 다층 퍼셉트론은

비선형 문제를 해결할 수 있으며, 이미지 분류, 자연어 처리 등 다양한 분야에서 활용된다. [31].

#### 4. 기계학습 실험 설정

분류 실험의 경우 WEKA 프로그램에서 제공해주는 Random Forest, Decision Stump, Naive Bayes, SMO 그리고 Multilayer Perceptron을 통해서 실험했고, 성능 평가에 사용한 데이터 설정은 Percentage split으로 70% 설정하여 실험했다. 기계학습의 각 알고리즘에 적용한 파라미터는 표 4를 통해 정리하였다.

표 4. WEKA 실험 설정

Table 4. Experiment options for WEKA

Random Forest	-P 100 -I 100 -num-slots 1 -K0 -M1.0
Decision Stump	does not have any functionality
Naive Bayes	does not have any functionality
SMO	-C1.0 -L0.001 -P1.0E-12 -N 0 -V -1 -W1 -K
Multilayer Perceptron	-L03 -M0.2 -N500 -V0 -S0 -E20 -Ha

한편, 회귀 실험의 분석은 Python 3.6을 활용하여 분석하였으며, 데이터 정제 및 가시화를 위해 Numpy, Pandas, Sklearn, Matplotlib 패키지를 활용하였다. 머신러닝(Random Forest, LightGBM Regression, Gradient boosting, XGBoost regression, Decision tree regression)을 통해서 실험했고, 성능 평가에 사용한 데이터 설정은 test\_size=0.3 설정하여 실험했다.

## IV. 실험 및 결과

우선 데이터별로 실험을 두 번씩 진행했다. 첫 번째는 별다른 수정을 하지 않고 실험했고, 두 번째는 WEKA 프로그램에서 제공해 주는 Select attributes 기능을 이용하여, feature selection을 적용하고 실험했다. Attribute Evaluator는 CorrelationAttributeEval을 사용했고, Search Method는 Ranker를 사용했다. Attribute Selection Mode는 Use full training set을 사용했다. Ranker를 기능 numToSelect을 이용해서 맨 처음에 10개씩 features을 선택하여 돌려보았다. 그러나 10개에 대하여 특징 선택을 한 결과, 전체를 택하여 기계학습을 실행한 결과와 차이점이 보이지 않아 본 실험에서는 전체의 데이터셋을 활용하여 실험을 진행하기로 하였다. 해당 실험 결과는 표 5로 정리되어 있다.

표 5. 회귀 문제에서 10개의 특징만을 선택한 기계학습 결과  
Table 5. Machine learning results of selecting 10 features with classification problem

Model	정확도	정밀도	민감도	특이도	f1-score
RF	75.02%	0.763	0.762	0.815	0.763
DST	68.25%	0.695	0.692	0.739	0.693
NB	61.90%	0.616	0.619	0.654	0.618
SVM	66.15%	0.662	0.662	0.704	0.662
MLP	58.03%	0.587	0.582	0.643	0.581

### 1. 회귀 문제에 대한 실험 결과

이제 악력의 참여에 영향을 미치는 예측 변인을 분석하기 위해 대상자 전체 4652의 데이터를 활용해 5가지 머신러닝 기법으로 RMSE, MAE, MSE,  $R^2$ 를 확인하였다. 그 결과, LightGBM Regression 모형의 RMSE가 5.082로 가장 낮게 나왔으며, 그 다음으로 Random Forest 5.163, Gradient Boosting 5.223, XGBoost Regression 5.351로 나타났다.

MSE(평균 제곱 오차)는 LightGBM Regression 모형이 25.83으로 가장 낮게 나타났으며, 그 다음으로 RandomForest 모형이 26.66, Gradient Boosting 27.28, XGBoost Regression 28.62로 나타나, MAE(평균 절대 오차)는 Random Forest 모형과 LightGBM Regression 모형이 3.978과 3.893으로 거의 유사하게 나타났고, Gradient Boosting 모형은 4.024로 나왔다. 역시  $R^2$ (R-제곱결정계수)도 LightGBM Regression 모형과 Random Forest 모형이 0.606과 0.593으로 이상으로 높게 나타난 것을 확인하였다. 악력을 예측하는데 있어서 가장 우수한 예측 제공 평균 오차와, 평균 제곱 오차, 평균 절대 오차를 보여준 모형은 LightGBM Regression 모형였다. 악력 예측에 대한 머신러닝 기법별 예측 결과는 표 6과 그림 3으로 요약하였다.

표 6. 악력에 대한 머신러닝 기법별 예측 결과 비교

Table 6. Comparison of Prediction Results for Grip Strength Using Various Machine Learning Techniques

Model	RMSE	MSE	MAE	$R^2$
RF	5.163	26.66	3.978	0.593
DTR	7.482	55.99	5.739	0.147
XGBR	5.351	28.62	4.119	0.564
LGBMR	5.082	25.83	3.893	0.606
GB	5.223	27.28	4.024	0.584

삶의 질은 Gradient Boosting 모형이 가장 우수한 결과를 보여 제공 평균 오차는 10.831로 나타났다. 이



그림 3. 다양한 머신러닝 기법을 활용하여 악력을 예측한 결과  
Figure 3. Results of Predicting Grip Strength Using Various Machine Learning Techniques

어서 Random Forest가 10.877, LightGBM Regression이 10.891의 성능을 보였다. MSE 측면에서도 Gradient Boosting이 117.32로 가장 뛰어났고, Random Forest가 뒤를 이었다. MAE에서는 세 모델이 비슷한 결과를 보였으며,  $R^2$  값에서는 Gradient Boosting과 Random Forest가 다른 모델들보다 높은 값을 기록했다.

주관적 건강상태는 Random Forest 모델이 0.557의 제공 평균 오차로 가장 우수한 성능을 보였으며, LightGBM Regression이 0.563, Gradient Boosting이 0.566, XGBoost Regression이 0.581의 결과를 보였다. MSE 측면에서는 Random Forest 모델이 0.311로 가장 우수했고, LightGBM Regression이 0.317, Gradient Boosting이 0.321, XGBoost Regression이 0.337의 성능을 보였다. MAE에서는 세 모델이 비슷한 결과를 보였다.  $R^2$  값에서는 Random Forest와 Gradient Boosting 모델이 다른 모델들보다 높은 값을 기록했다. Random Forest가 0.491, Gradient Boosting이 0.474로 순위를 차지했다.

건강 상태는 Gradient Boosting 모델이 0.588의 제공 평균 오차로 가장 우수한 성능을 보였으며, LightGBM Regression이 0.589, Random Forest가 0.592, XGBoost Regression이 0.602를 기록했다. MSE 측면에서는 Gradient Boosting 모델과 LightGBM Regression 모델이 0.346로 가장 우수했고, Random Forest 모델이 0.351, XGBoost Regression 모델이 0.363의 결과를 보였다. MAE에서는 LightGBM Regression이 0.457로 우수한 성과를 보였고, Gradient Boosting 모델과 Random Forest 모델이

0.464로 유사한 결과를 보였다.  $R^2$  값에서는 Gradient Boosting 모델과 LightGBM Regression 모델이 아주 작은 차이로 0.456과 0.455를 기록했다.

다음으로 삶의 질, 주관적 건강상태, 건강상태도 LightGBM Regression 모형과 Gradient Boosting 모형이 다른 모형에 비해 잘 예측하는 양상을 보인다. 삶의 질, 주관적 건강 상태, 건강 상태에 대한 머신러닝 기법별 예측 결과는 표 6-8, 그림 4-6으로 요약하였다.

표 7. 삶의 질에 대한 머신러닝 기법별 예측 결과 비교  
 Table 7. Comparison of Prediction Results for Quality of Life Using Various Machine Learning Techniques

Model	RMSE	MSE	MAE	$R^2$
RF	10.877	118.31	8.074	0.535
DTR	15.156	229.72	10.709	0.098
XGBR	11.351	128.85	8.347	0.494
LGBMR	10.891	118.59	8.081	0.534
GB	10.831	117.32	8.092	0.539



그림 4. 다양한 머신러닝 기법을 활용하여 삶의 질을 예측한 결과

Figure 4. Results of Predicting Quality of Life Using Various Machine Learning Techniques

표 8. 주관적 건강상태에 대한 머신러닝 기법별 예측 결과 비교  
 Table 8. Comparison of Prediction Results for Subjective Health Status Using Various Machine Learning Techniques

Model	RMSE	MSE	MAE	$R^2$
RF	0.557	0.311	0.421	0.491
DTR	0.758	0.575	0.474	0.058
XGBR	0.581	0.337	0.444	0.447
LGBMR	0.563	0.317	0.427	0.481
GB	0.566	0.321	0.429	0.474

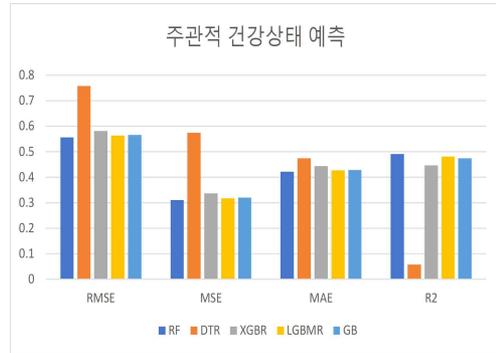


그림 5. 다양한 머신러닝 기법을 활용하여 주관적 건강상태를 예측한 결과

Figure 5. Results of Predicting Subjective Health Status Using Various Machine Learning Techniques

표 9. 건강상태에 대한 머신러닝 기법별 예측 결과 비교  
 Table 9. Comparison of Prediction Results for Health Status Using Various Machine Learning Techniques

Model	RMSE	MSE	MAE	$R^2$
RF	0.592	0.351	0.464	0.451
DTR	0.866	0.751	0.579	0.176
XGBR	0.602	0.363	0.471	0.429
LGBMR	0.589	0.346	0.457	0.455
GB	0.588	0.346	0.464	0.456

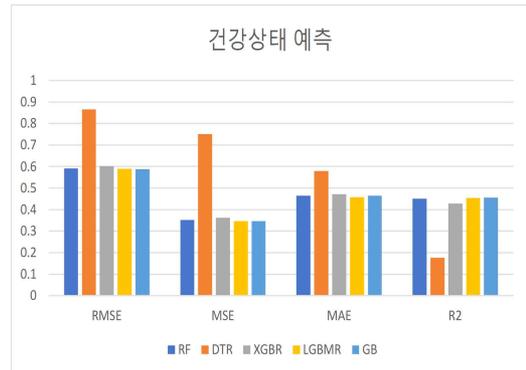


그림 6. 다양한 머신러닝 기법을 활용하여 건강상태를 예측한 결과

Figure 6. Results of Predicting Health Status Using Various Machine Learning Techniques

## 2. 분류 문제에 대한 실험 결과

고령층의 경제활동 참여에 영향을 예측하기 위해 대상자 전체 5717명의 데이터를 활용하여 다섯 가지 머신러닝 기법을 적용하여 모델을 구축하고 평가하였다.

평가 지표로는 정확도, 정밀도, 민감도, 그리고 f1-score를 사용하였다. RF 모형의 정확도가 99.70%로 가장 높았으며, 그 다음으로 DTS 99.65% MLP 93.99%로 나타났다. 다음으로 NB 90.67%, 마지막으로 SVM 모형이 70.33%로 가장 예측 정확도가 낮게 난 것을 확인할 수 있다. 정밀도는 RF 모형과 DTS 모형이 0.992로 가장 높았고, 그 다음이 MLP 모형으로 0.831, SVM 0.826 NB 모형이 0.778로 나타나, NB 모형의 성능이 떨어졌다. 민감도를 기준으로 판단한 결과, RF 모형의 성능이 0.992로 가장 높았고, SVM 모형의 성능이 0.711로 가장 낮았다. 특이도에서도 RF, DTS와 SVM 모형이 유사하게 나타났고, NB와 MLP의 모형이 각각 0.878, 0.986으로 나타나 낮은 특이도를 보였다. f1-score도 역시 RF와 DTS 모형이 0.995로 가장 높게 나타난 것을 확인하였다. 해당 결과들은 표 10과 그림 7로 요약하였다.

표 10. 고령층 경제활동에 대한 머신러닝 기법별 예측 결과 비교

Table 10. Comparison of Prediction Results for Economic Activity of the Elderly Using Various Machine Learning Techniques

Model	정확도	정밀도	민감도	특이도
RF	99.70%	0.992	0.992	0.996
DTS	99.65%	0.992	0.992	0.996
NB	90.67%	0.778	0.911	0.878
SVM	70.33%	0.826	0.711	0.996
MLP	93.99%	0.831	0.821	0.986

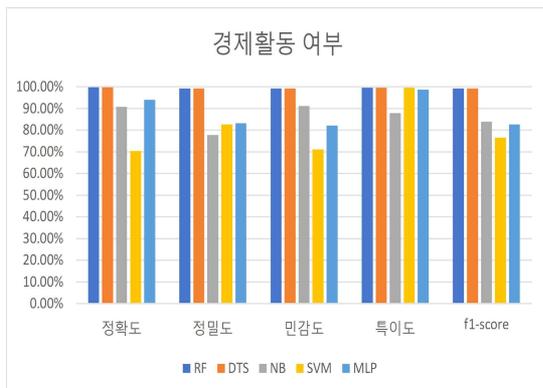


그림 7. 다양한 머신러닝 기법을 활용하여 고령층의 경제활동을 예측한 결과

Figure 7. Results of Predicting Economic Activity of the Elderly Using Various Machine Learning Techniques

한편 임금노동 여부를 예측하는 데 있어서 제일 좋은 기계학습 모델 역시 76.02%의 정확도를 기록한 랜덤 포레스트로 나타났다. 이후로 DT 69.25%, SVM 66.15%로 나타났다. NB는 61.90%, 마지막으로 MLP 모형 58.03%으로 가장 예측 정확도가 낮게 난 것을 확인할 수 있다.

정밀도는 RF 모형 0.765로 가장 높았다. 그다음으로 DTS와 SVM 모형이 0.695, 0.662로 가장 높았고, 그다음이 NB 모형으로 0.617, MLP 모형이 0.586으로 나타나, MLP 모형의 성능이 가장 떨어졌다. 민감도를 기준으로 판단한 결과, RF 모형의 성능이 0.761로 가장 높았고, MLP 모형의 성능이 0.581로 가장 낮았다. 특이도에서도 RF 0.813으로 가장 높았고, DT 모형 0.739, SVM 0.704, NB 0.656, MLP 0.641으로 나타나 가장 낮은 특이도를 보였다. f1-score 역시 RF 모형이 0.761로 가장 높게 나타난 것을 확인하였다. 해당 과정은 표 11과 그림 8로 요약하였다.

표 11. 고령층 임금노동에 대한 머신러닝 기법별 예측 결과 비교

Table 11. Comparison of Prediction Results for Wage Labor of the Elderly Using Various Machine Learning Techniques

Model	정확도	정밀도	민감도	특이도
RF	76.02%	0.765	0.761	0.813
DT	69.25%	0.695	0.692	0.739
NB	61.90%	0.617	0.619	0.656
SVM	66.15%	0.662	0.662	0.704
MLP	58.03%	0.586	0.581	0.641

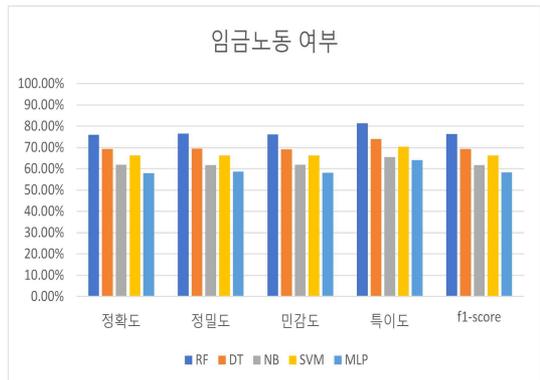


그림 8. 다양한 머신러닝 기법을 활용하여 고령층 임금노동을 예측한 결과

Figure 8. Results of Predicting Wage Labor of the Elderly Using Various Machine Learning Techniques

### 3. 실험 결과에 대한 논의

실험 결과를 살펴보면 Regression 문제에 대한 결과를 살펴보면, 약력 예측을 위한 모델에서는 LightGBM Regression 모델이 가장 우수한 성능을 보였다. RMSE, MSE, MAE,  $R^2$  값 모두에서 다른 모델들보다 우수한 성과를 보였으며, 특히  $R^2$  값에서 높은 설명력을 보여줬다. 이러한 결과는 LightGBM Regression 모델이 약력과 관련된 데이터를 효과적으로 학습하고 예측할 수 있는 능력을 갖고 있다는 것을 제공한다. 그러나, 삶의 질, 주관적 건강상태, 건강상태 예측에 대해서는 Gradient Boosting 모델도 매우 우수한 성능을 보였다. 특히, 삶의 질과 건강상태 예측에서는 Gradient Boosting 모델이 LightGBM Regression 모델과 유사한 성과를 보였으며, 이는 두 모델이 비슷한 수준의 예측 능력을 갖고 있다는 것을 시사한다. 또한, Random Forest 모델도 주관적 건강상태 예측에서 우수한 성능을 보였다.

Classification 문제에 대한 결과를 보면, 고령층의 경제활동 참여 예측에서는 Random Forest 모델이 가장 높은 정확도를 보였다. 이는 Random Forest 모델이 복잡한 데이터에서도 뛰어난 예측 능력을 발휘한다는 것을 시사한다. 또한, 각 모델의 정밀도, 민감도, 특이도, f1-score 등의 성능 지표를 살펴본 결과, 각 모델마다 장단점이 있음을 확인할 수 있었다. 예를 들어, MLP 모델은 정확도 측면에서는 낮은 성능을 보였지만, 다른 모델들보다 높은 정밀도를 보였다. 그러나, 실험 결과를 종합해보면, 각각의 문제에 대해 다양한 머신러닝 기법이 서로 다른 수준의 성능을 보였다. 예를 들어, Regression 문제에서는 LightGBM Regression 모델이 약력 예측에 뛰어난 성능을 보였지만, 삶의 질과 건강상태 예측에서는 Gradient Boosting과 Random Forest 모델도 높은 성과를 보였다. 이러한 다양한 성능은 하나의 알고리즘이 모든 문제에 대해 최고의 성능을 보장하지 않음을 보여준다. 따라서, 모델 선택에 있어서는 각 모델의 특성을 고려하여 적합한 모델을 선택하는 것이 중요하다. 이는 모든 예측 문제에서 전반적으로 우수하고 최상의 성능을 발휘하는 기계학습 알고리즘이 없다는 것이다.

실험 결과를 통해 알 수 있는 한계점은 몇 가지 존재한다. 우선, 실험에 사용된 데이터의 품질과 양이 모델의 성능에 영향을 줄 수 있다. 더 많은 데이터와 더

좋은 품질의 데이터를 사용하면 모델의 예측 능력을 높일 수 있을 것이다. 또한, 실험에서 사용된 특성(feature)의 선택과 모델의 파라미터 설정에 따라 성능이 달라질 수 있다. 따라서 모델 구축 시 특성 선택과 파라미터 조정에 대한 더 깊은 탐구가 필요할 것이다.

## V. 결 론

실험 결과를 종합하여 결론을 써보자면, 우선 실험 결과를 통해 다양한 머신러닝 기법이 주어진 문제에 대해 각기 다른 성능을 보인다는 것을 확인했다. Regression 문제에서는 LightGBM Regression 모델이 우수한 성능을 보였으며, Classification 문제에서는 Random Forest 모델이 높은 정확도를 보였다. 이러한 결과는 문제의 특성에 따라 적합한 모델을 선택하는 것이 중요하다는 점을 강조한다. 둘째로, 실험 결과를 통해 각 모델의 장단점을 파악할 수 있었다. 예를 들어, MLP 모델은 정확도 측면에서는 다소 낮은 성능을 보였지만, 다른 모델들보다 높은 정밀도를 보였다. 이러한 장단점을 고려하여 모델을 선택하고 활용함으로써 예측 성능을 향상시킬 수 있을 것이다. 셋째로, 실험에서는 데이터의 품질과 양, 특성 선택, 파라미터 설정 등이 모델의 성능에 영향을 미친다는 점을 고려했다. 그리고 후속 연구에서는 다양한 전처리 기법을 적용하여 모델의 성능을 향상시킬 수 있는 가능성을 탐구할 필요가 있다. 예를 들어, 데이터 정제, 이상치 처리, 특성 스케일링 및 변환 등을 새로운 방법으로 시도하여 모델의 예측 능력을 높일 수 있다. 또한, 다른 변수를 추가하거나 기존 변수를 변형하여 모델의 입력 특성을 보다 풍부하게 만드는 것이 중요하다. 새로운 도메인 지식을 활용하여 모델에 새로운 특성을 추가하거나 기존 특성을 조정함으로써 모델의 성능을 향상시킬 수 있다. 마지막으로, 다른 데이터 소스를 활용하여 실험을 확장하는 것도 유익할 것이다. 새로운 설문 조사 데이터를 수집하거나 공개된 데이터셋을 활용하여 모델의 일반화 성능을 평가하고 새로운 통찰력을 얻을 수 있다.

따라서 이러한 다양한 접근 방법을 통해 모델의 성능을 향상시키고 응용 가능성을 확장할 수 있을 것으로 기대된다. 후속 연구에서는 이러한 측면을 고려하여 연구를 진행하고 결과를 보고할 때 참고할 수 있도록 한다.

## References

- [1] J. Min, "Effect of Social Engagement on Self-rated Health Trajectory among Korean Older Adults," *Health and Social Welfare Review*, 2013. 33(4): p. 105-123.
- [2] S. M. Park, "Effects of Health Status on Life-Satisfaction of the Elderly -Focusing on the mediating and moderating effects of social activities and economic activities-, " *Journal of Welfare for the Aged*, 2011. 53: p. 305-332. doi: 10.21194/kjgsw..53.201109.291
- [3] K. Son and K. Kim, "Analysis of the Effects of Self-Perceived Health on Life Satisfaction and Mediating Effect of Social Activities of the Elderly by Age Group", *The Journal of the Korea Contents Association*, 2020. 20(7): p. 127-138. doi: 10.5392/JKCA.2020.20.07. 127
- [4] W. Yoon, "The effects of usual source of care on Health-behaviors of chronic disease patients," Master dissertation, Seoul National University, 2014.
- [5] C. Kim, "Characteristics of geriatric diseases," *The Korean Journal of Medicine*, 2006. 71(2): p. 844-847.
- [6] <https://survey.keis.or.kr/klosa/klosa04.jsp>
- [7] S. Kim, "Confidence, Happiness and Relationship of the Participation Leisure Activities," *Korea Sport Research* 2006. 17(5): p. 561-571.
- [8] S. H. Kim, "Benefits of Volunteering to Physical health, Depression, Social Support, and Meaning in Life among Older Adults," *Journal of the Korea Gerontological Society*, 2013. 33(1): p. 53-66.
- [9] K. Pynnönen, et al., "Does social activity decrease risk for institutionalization and mortality in older people?" *Journals of Gerontology Series B: Psychological Sciences and Social Sciences*, 2012. 67(6): p. 765-774. doi: 10.1093/geronb/gbs076
- [10] P. A. Thomas, "Trajectories of social engagement and mortality in late life," *Journal of Aging and Health*, 2012. 24(4): p. 547-568. doi: 10.1177/0898264311432310
- [11] H. S. Gweon, "The Effect of Social Participation on the Life Satisfaction of the Elderly -Focusing on the Mediating Effects of Depression and Self-reported Health-, " *Korean Journal of Human Ecology*, 2009, 18(5): p. 995-1008
- [12] H. G. Koenig, et al., "Does religious attendance prolong survival? A six-year follow-up study of 3,968 older adults," *Journals of Gerontology Series A: Biomedical Sciences and Medical Sciences*, 1999. 54(7): p. M370-M376. doi: 10.1093/gerona/54.7. m370
- [13] S. K. Lutgendorf, et al., "Religious participation, interleukin-6, and mortality in older adults," *Health Psychology*, 2004. 23(5): p. 465. doi: 10.1037/0278-6133.23.5.465
- [14] J. A. Burr, J. Tavares, and J.E. Mutchler, "Volunteering and hypertension risk in later life," *Journal of Aging and Health*, 2011. 23(1): p. 24-51. doi: 10.1177/0898264310388272
- [15] T. Y. Lum, and E. Lightfoot, "The effects of volunteering on the physical and mental health of older people," *Research on aging*, 2005. 27(1): p. 31-55. doi: 10.1177/0164027504271349
- [16] E. P. Sabin, "Social relationships and mortality among the elderly," *Journal of Applied Gerontology*, 1993. 12(1): p. 44-60. doi: 10.1177/073346489301200105
- [17] M.-S. Kim and J.-W. Ko, "The Effect of the Elderly's Leisure Activity on Their Health and the Mediating Role of Family Support," *Journal of Welfare for the Aged*, 2013. 60: p. 35-54. doi: 10.21194/kjgsw..60.201306.35
- [18] H.-R. Kim and K.-W. Lee, "The Relationship between the Participation of the Female Elderly in the Leisure Activity, and Physical Health and a Sense of Happiness," *Journal of Sport and Leisure Studies*, 2008. 34: p. 671-680
- [19] B. Kye, "Population aging, socioeconomic development and social inequality," *Economy and Society*, 2015. 106: p. 41-72.
- [20] Y.-S. Koh, "A Exploratory Study on the Digital Aging Policies as Solutions for a Aging Society," *Journal of Digital Convergence*, 2016. 14(11): p. 115-123. doi: 10.14400/JDC.2016.14.11.115
- [21] Y. Choi and Y. Yoon, "Data Preprocessing for Predictiong Sarcopenia Based on Machine Learning," *The Journal of the Convergence on Culture Technology*, 2023. 9(3): p. 737-744. doi: 10.17703/JCCT.2023.9.3.737
- [22] E. Frank, M. A. Hall and I. H. Witten, *The WEKA Workbench. Online Appendix for "Data*

- Mining: Practical Machine Learning Tools and Techniques”, Morgan Kaufmann, Fourth Edition, 2016.
- [23] P. J. Kim, “An analytical study on automatic classification of domestic journal articles using random forest,” Journal of the Korean Society for Information Management, 2019. 36(2): p. 57-77. doi: 10.3743/KOSIM.2019.36.2.057
- [24] P. S. M. Reddy, “Decision tree regressor compared with random forest regressor for house price prediction in mumbai,” Journal of Survey in Fisheries Sciences, 2023. 10(1S): p. 2323-2332. doi: 10.17762/sfs.v10i1S.465
- [25] M. Kang, “How Design Elements of a Social Q&A Site Influence New Users’ Continuance Behavior: An Application of Logistic Regression and XGBoost Techniques,” Knowledge Management Research, 2023. 24(2): p. 161-183. doi: 10.15813/kmr.2023.24.2.008
- [26] J.-H. Kim, “Machine Learning Classifier Models for Predicting Sarcopenia in the Elderly Based on Physical Factors,” medRxiv, 2023: p. 2023.05. 03.23288546.
- [27] K. Yongcharoenchaiyasit et al., “Gradient Boosting Based Model for Elderly Heart Failure, Aortic Stenosis, and Dementia Classification,” IEEE Access, 2023. 11: p. 48677-48696. doi: 10.1109/ACCESS.2023.3276468
- [28] S. Badgujar and A.S. Pillai. “Fall detection for elderly people using machine learning,” in 2020 11th international conference on computing, communication and networking technologies (ICCCNT). 2020. IEEE. doi: 10.1109/ICCCNT49239.2020.9225494
- [29] J. Wolfson et al., “A Naive Bayes machine learning approach to risk prediction using censored, time to event data,” Statistics in medicine, 2015. 34(21): p. 2941-2957. doi: 10.1002/sim.6526
- [30] J. H. Shin, B. Lee, and K.S. Park, “Detection of abnormal living patterns for elderly living alone using support vector data description,” IEEE Transactions on Information Technology in Biomedicine, 2011. 15(3): p. 438-448. doi: 10.1109/TITB.2011.2113352
- [31] X. Song et al. “Comparison of machine learning techniques with classical statistical models in predicting health outcomes,” in MEDINFO 2004. 2004. IOS Press. doi: 10.3233/978-1-60750-949-3-736

※ 이 논문은 정부(과학기술정보통신부, 교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No.2022R1F1A1066017, NRF-2022S1A5C2A07090938)