

# 인공신경망을 활용한 주택연금의 해지 위험 예측 성능평가

## Evaluating the Risk Prediction Performance of Reverse Mortgages Using Artificial Neural Networks

이우식<sup>1</sup>, 최경진<sup>2\*</sup>

Woosik Lee<sup>1</sup>, Kyung-jin Choi<sup>2\*</sup>

### 요 약

최근 빅데이터 시대가 도래하면서 인공 신경망 모델을 포함한 기계학습모델들이 다양한 의학 영역과 유전체 연구 그리고 기업의 생존 등에 이르기까지 굉장히 광범위한 영향력을 행사하며 그 영역을 넓혀가고 있지만, 생존 분석을 기계학습에 적용한 국내 계량 금융·보험 연구들은 충분히 축적되지 못하고 있는 상황이다. 본 연구는 주택연금 가입자의 데이터와 인공신경망 모델을 활용한 생존 분석 모델을 설계하고, 우위성 지수를 통한 판별분석 측면에서 최적화 알고리즘인 Adam, RMSProp 그리고 SGD를 비교·분석하였다. 본 연구 수행에 따른 실증 분석의 주요 결과를 요약·정리해 제시하면 다음과 같다. 첫째, 전통적인 통계 모형과 인공신경망 모형을 생존 분석에 적용하여 주택연금 가입자의 해지 예측한 결과, 인공신경망과 Adam 최적화 알고리즘을 사용한 모형이 좀 더 개선된 예측 값을 제공하였다. 이는 생존 분석에 인공신경망을 결합한 모형이 연금 가입자의 해지 예측 문제에 응용될 수 있다는 점을 확인했다. 둘째, SGD와 RMPProp과 인공신경망을 결합한 모형의 위험 예측 결과가 전통적인 콕스 비례위험모형보다 약간 낮았다. 이를 통해 최적화의 중요성과 더불어 운동량(Momentum)의 개념 및 적응형 방법(Adaptive Method)을 동시 적용한 Adam 최적화 알고리즘의 우수한 학습 성능도 또한 확인할 수 있게 됐다. 마지막으로 본 연구는 인공신경망 기법을 주택연금에 최초로 적용하였다는 점에서 의미가 있다. 향후에는 주택연금 뿐 만 아니라 다른 연금 보험 데이터에 응용할 수 있는 일반화 가능성을 보여준다.

핵심어 : 비즈니스 애널리틱스, 인공지능, 계량금융·보험, 최적화, 생존분석

### Abstract

Machine learning models, particularly artificial neural networks, have had a wide range of affects in numerous sectors such as medical science, genetics, business, and so on since the advent of the big data age. In Korea, however, there has been an insufficient accumulation of quantitative insurance research using machine learning models for survival analysis. Using data from reverse mortgage subscribers and an artificial neural network model, this study created a survival analysis model, then compared and examined optimization algorithms such as Adam, RMSProp, and SGD in terms of discriminant analysis using a Concordance Index. The primary findings of the empirical analysis conducted in this study are as follows.

- 1 College of Business Administration, Gyeongsang National University, Jinju, Korea [Professor]  
e-mail: woosiklee@gnu.ac.kr
- 2 College of Business Administration, Gyeongsang National University, Jinju, Korea [Professor]  
e-mail: choikj23@gnu.ac.kr (Corresponding author)

Received(July 13, 2023), Review Result(1st: July 29, 2023), Accepted(August 11, 2023), Published(August 31, 2023)



© 2023 The Authors. Published by NCISS.  
This is an open access article licensed under the Creative Commons Attribution-NonCommercial 4.0 International License.  
To view a copy of this license, visit <http://creativecommons.org/licenses/by-nc/4.0/>.

First, both classic statistical model and artificial neural network model are applied to survival analysis to predict the termination of reverse mortgage. This shows the utility of merging artificial neural networks with survival analysis for forecasting reverse mortgage cancellation and the potential for generalization to other pension insurance data. Second, the risk prediction results of the model that combined the artificial neural network with SGD and RMSProp optimization algorithms were slightly lower than the classic Cox proportional hazards model. This confirmed the importance of optimization as well as the superior learning performance of the Adam optimization algorithm, which also integrates momentum and adaptive approaches.

Keyword : Business Analytics, Artificial Intelligence, Quantitative Finance·Insurance, Optimization, Survival Analysis

## 1. 서론

주택연금은 2007년 7월 도입된 공적보증의 역모기제도이다. 현재 주택연금의 가입 대상은 부부 중 55세 이상인 공시가격 9억 원 자가주택 보유자이다. 주택연금은 제도 활성화를 위해 가입대상 연령의 하향과 가입대상 주택 가격을 확대한 결과, 주택연금 가입자 수는 꾸준히 증가하였다. 2022년 말 기준 누적 가입건수는 106,591건에 도달하였다. 반면, 양적 성장에 비례하여 해지 건수도 증가하고 있다. 주택가격이 급등한 2020년과 2021년의 경우, 큰 폭으로 해지가 증가했지만, 주택가격 하락이 시작된 2022년에는 중도해지가 감소하는 형태를 보인다. 주택연금제도의 질적 성장 및 제도 발전을 모색하기 위한 측면에서 축적된 해지 데이터에 근거한 분석 및 예측이 필요한 시점이다. 본 연구와 관련이 있는 주택연금 해지와 관련한 연구로는 최경진외 2인 연구 [1], 전희주 연구 [2], 최경진과 전희주 연구 [3], 류기운외 2인 연구 [4], 김병국 연구 [5], 김윤수와 이용만 연구 [6], 전유정과 유선종 연구 [7], 김경선과 신승우 연구 [8], 유선종과 노민지 연구 [9], Jiang and Miller 연구 [10] 등이 있다. 이들 연구 중 최경진외 2인 연구 [1]는 콕스비례위험(Cox Proportional Hazards) 모형을 활용하여 해지에 미치는 위험요인을 분석하였다. 나머지 문헌들은 주택연금 해지 요인을 분석하였는데 분석방법은 생존분석과 이항 또는 다항로짓모형, 프로빗 모형 등을 활용하여 중도해지 확률에 유의한 영향을 미치는 요인을 도출하고자 하였다 [5][6]. 이처럼 대부분의 선행 연구는 전통적인 통계기법만을 활용하였다. 하지만 최근 빅데이터 시대가 도래하면서 인공 신경망 모형을 포함한 기계학습(Machine Learning)모형들이 다양한 의학 영역과 유전체 연구 그리고 기업의 생존 등에 이르기까지 굉장히 광범위한 영향력을 행사하며 그 영역을 넓혀가고 있지만, 생존 분석(Survival Analysis)을 기계학습에 적용한 국내 계량 금융·보험 연구들은 충분히 축적되지 못하고 있는 상황이다. 기계학습모형은 전통적인 통계 모형과 달리 특정한 이론이나 가정에 기반하지 않고, 데이터 기반의 학습을 통해 정확한 예측을 목표로 구축된다. 이에 본 연구는 주택연금 가입자의 데이터와 인공 신경망(Artificial Neural Network) 모형을 통한 연금 해지 위험 예측 성능을 비교 및 분석해 선행연구와의 차별성을 강조하고자 한다.

한편, 본 논문은 다음과 같이 4개 장(章)으로 구성되어 있다. 제1장 서론에서는 본 연구 수행의

계기와 관련해 그 배경과 필요성을 정리해 제시한다. 그다음 제2장에서는 본 연구의 주요 방법론인 인공지능망 모형과 최적화 알고리즘(Optimization Algorithm)에 관한 이론적 근거를 고찰한 결과를 요약해 제시한다. 그다음 제3장에서는 실증 연구를 위한 방법론을 정립한 뒤 실증 분석에 의해 도출된 결과를 밝힌다. 마지막 제4장에서는 본 연구 결과를 토대로 그 의의 및 시사점을 제시함으로써 연구의 결론을 마무리한다.

## 2. 이론적 배경

### 2.1 인공지능망

인공지능망 모형은 층(Layer)을 비롯해 연결의 강도, 학습 알고리즘, 전이 함수 등의 구성 요소로 이뤄진 데이터 처리 시스템을 뜻한다. 인공지능망 모형은 대부분 입력층 및 출력층과 함께 은닉층의 3가지 부분으로 구성되어 있는데, 처리 단위인 뉴런이 이들 각 층에 존재한다 [11].

입력층에서는 외부로부터 입력 자료를 받아들여 이를 데이터처리 시스템으로 전송한다. 이 시스템을 구성하는 층 중 하나인 은닉층은 입력된 값을 입력층으로부터 넘겨받아서 소정의 처리 과정을 거쳐 출력층으로 내보낸다. 인공지능망 모형 또한 판별모형처럼 입력된 자료를 기반으로 각 입력변수별로 상대적 가중치가 인식패턴의 결과로서 기억이 된다. 이렇게 처리된 결과들이 인공지능망 모형의 마지막 결과로 남게 된다. 이것은 다시 말해 인공지능망 구조가 서로 다른 층에 위치해 있는 뉴런의 가중치로 상호 연결되어 있음을 뜻한다 [11].

이와 같이 인공지능망이 인식한 패턴은 각 층에 존재하는 뉴런과 뉴런 간의 상호 연결의 강도에 의해 결정이 된다. 이에 따라 인공지능망의 구조는 다른 층에 각자 위치해 있는 뉴런들 간 서로 연결된 구조를 취하고 있다고 이해할 수 있다. 각각의 처리 단위는 이렇게 서로 연결된 다른 처리 단위에서 입력된 입력함수로 가중합을 해서 순입력 값을 산출한다. 이때 순입력 값의 합계는 전이함수를 이용해서 그 처리 단위의 출력된 값에 의해 산출된다. 이 같은 과정을 거쳐 산출된 인공지능망에 의해 결정된 예측 값과 실제 값을 서로 비교해 그 차이를 감소시켜 나감으로써 연결 강도를 조절해 실제 값에 수렴되도록 작동한다. 이러한 제반 과정을 학습 알고리즘이라고 부른다. 인공지능망에 의해 구현되는 이 같은 학습 알고리즘은 예측 값과 실제 값을 비교하여 그 차이를 감소시키는 방법을 통해 연결 강도를 조절된 실제 값에 수렴되도록 유도한다. 학습 알고리즘은 한마디로 주어진 특정 문제에 대한 연결 강도의 값을 구하는 절차라 할 수 있다 [11].

역전파는 인공지능망에 의해 구현되는 여러 학습 알고리즘들 중 하나로서 다음의 과정을 일반적으로 거친다. 먼저 학습 대상 패턴이 입력층에 존재하는 각 뉴런에 입력이 되면, 그다음 이 신호들은 각 은닉층에서 종합이 된 후 전이함수를 거쳐서 출력층으로 전달이 된다. 이렇게 여러 단계를 지나 출력층에 전달이 된 값은 은닉층에서 수행되는 절차와 동일하게 출력 값으로 산출이 되어

서 실제 값과 서로 비교를 행하는 과정을 거치게 된다. 이때 출력 값 및 실제 값을 상호 비교한 후 이들 값 사이에 발생한 차이를 최소한으로 줄이기 위한 과정으로 나아간다. 이 과정에서는 역으로 각 처리 요소에 연결된 뉴런의 연결 강도를 다시 조정하고 재차 순방향으로의 계산, 역방향으로의 연결강도 조정을 지속함으로써 모든 패턴의 값을 만족시킬 수 있게끔 오차를 최소화하는 방향으로 학습을 수행해 최종적으로 예측을 행하는 알고리즘인 것이다 [11].

## 2.2 최적화 알고리즘

본 연구에서는 인공지능망을 이용한 생존 분석 모형의 성능 평가를 목적으로 다양한 초매개변수(Hyperparameter)들 중에서 최적화 알고리즘인 경사하강법(Gradient Descent)에 초점을 맞춰 자료 분석을 실시하고자 한다. 여기서 경사하강법은 인공지능망에 의한 학습 수행 시, 손실 함수나 비용 함수가 최소화될 수 있도록 가중치의 조절을 위해서 적용하는 최적화 알고리즘이라 할 수 있다 [12]. 경사하강법은 이러한 장점을 갖고 있지만, 경사하강법의 적용에 있어 단점 또한 존재한다. 경사하강법은 한 번의 가중치 갱신을 위해서 전체 데이터를 사용하는데, 이 때문에 비효율적이라는 지적에서 자유롭지 못하고 학습 시간 또한 상대적으로 길다는 점에서 단점도 갖고 있다. 이런 단점을 보완하기 위해서 확률적 경사하강법(Stochastic Gradient Descent, SGD)이 제안되었다 [12]. 이 개선된 알고리즘은 데이터에 대한 샘플링을 통해 비교적 적은 데이터를 가지고 학습을 하고, 이 같은 과정을 수차례 반복함으로써 확률적으로 볼 때 전체 데이터를 가지고 학습하는 것과 유사한 효과를 나타낸다. 하지만 이러한 개선에도 불구하고 확률적 경사하강법이나 일반적인 경사하강법, 이 두 알고리즘은 학습 도중 극솟값에 빠져서 최솟값의 발견이 어려운 경우가 발생한다는 단점이 여전히 존재한다 [12]. 이에 본 연구에서는 Adaptive Moment Estimation(Adam), Stochastic Gradient Descent(SGD), Root Mean Square Propagation(RMSProp) 최적화 경사하강법 알고리즘의 대안적 활용을 통해 인공지능망을 학습하고자 한다.

### 2.2.1 Adaptive Moment Estimation(Adam)

본 연구가 적용하고자 하는 대안적 알고리즘 중 하나로서 Adam 알고리즘은 Momentum 알고리즘 및 RMSProp 알고리즘의 특성을 고루 반영한 알고리즘인데, 여기서 Momentum 알고리즘은 가중치의 변경 값에 관성(Momentum)을 추가한 것이다. 이 Adam 알고리즘은 최적화에 따른 갱신 경로에 변경을 가하는 운동량(Momentum)의 개념을 토대로 일정 부분 과거 갱신 정보를 반영하면서, 동시에 새롭게 산정된 경사 방향과의 조합을 통해 최종 갱신 크기를 산출한다. 이것은 다시 말해 운동량과 같이 현재까지 계산 수행한 기울기의 지수 평균을 우선 저장한 다음에 아래 식처럼 RMSProp 알고리즘 기울기에 대한 제곱 값의 지수 평균(Exponential Average)을 순차적으로 저장한다 [12].

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) \nabla_w J(w) \quad (1)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) (\nabla_w J(w))^2 \quad (2)$$

위의 식에서  $m_t$  및  $v_t$ 는 1차 운동량, 2차 운동량의 추정 값을 각각 나타낸다. 또한  $\beta_1$  및  $\beta_2$ 는 감쇠 비율(decay rate)로서 운동량 측정 시 활용되는 고정 변수인데, 이들 변수의 값으로는  $\beta_1$ 의 경우 0.9,  $\beta_2$ 의 경우에는 0.999를 일반적으로 사용한다. 이 같은 갱신 방식만을 활용할 때, 그 운동량의 초깃값은 0이므로, 갱신 크기가 초반에 매우 작아지는 문제를 야기하게 된다. 이런 문제점의 보정을 위해서 Adam 알고리즘은 아래 식처럼 1차 및 2차 운동량의 추정치에 대한 편향 보정을 한다 [12].

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^n} \quad (3)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^n} \quad (4)$$

여기서  $\hat{m}_t$ 과  $\hat{v}_t$ 는 보정이 이루어진 운동량의 추정치다. 이에 따라 RMSProp 알고리즘 특성에 운동량의 개념을 추가 적용한 Adam 알고리즘에 관한 식은 아래의 수식 (5)와 같이 표현된다.

$$w = w - \frac{\eta}{\sqrt{\hat{v}_t} + \epsilon} \quad (5)$$

### 2.2.2 Stochastic Gradient Descent(SGD)

Stochastic Gradient Descent(SGD) 최적화 알고리즘은 손실함수 기울기를 계산하여 새로운 매개변수를 갱신하는 방법으로 아래의 식과 같이 표현된다 [13].

$$w = w - \eta \nabla_w J(w) \quad (6)$$

$J(w)$ 는 현재의 손실함수이고  $\eta$ 는 학습률이다. 학습률은 미리 정해 놓은 값이며 보통 0.01에서 0.001사이의 값을 사용한다. 이를 기본으로 하여 현재 계산된 손실함수 기울기의 반대 방향으로 이동을 하고 새로운 가중치로 다시 사용한다.

### 2.2.3 Root Mean Square Propagation(RMSProp)

RMSProp 알고리즘은 AdaGrad 알고리즘의 G를 개선한 알고리즘으로 이전 변화량 및 현재 변화량의 지수 평균(Exponential Average)으로 정의되므로, 학습률의 급격한 감소 현상을 미연에 방지하는 것이 가능하다 [14]. 즉, 최신에 학습한 데이터가 가중치 변경에 좀 더 많은 영향을 미치도록 설계되었다 [14].

$$G = \gamma G + (1 - \gamma) \nabla_w J(w) \odot \nabla_w J(w) \quad (7)$$

$$w = w - \frac{\eta}{\sqrt{G + \epsilon}} \odot \nabla_w J(w) \quad (8)$$

### 3. 우위성 지수(Concordance Index)

판별력(Discrimination)은 모형이 결과 변수의 유무에 따라 자료를 정확하게 구분하는 능력을 의미한다. 본 연구에서는 생존 분석에서 가장 많이 활용되는 판별력 평가 도구인 Harrell's 우위성 지수를 통해 판별력을 평가하였다 [15]. 우위성 지수는 이진 분류 모형을 평가하는 Area Under the Receiver Operating Curve(AUC)를 절단된 자료에 활용할 수 있도록 확장된 형태로 모형이 자료 사이에서 결과 변수가 발생하는 순서를 얼마나 잘 예측하는지를 평가하는 도구이다 [15]. 무작위 모형의 경우, 우위성 지수의 값은 0.5이며, 완벽한 모형의 경우, 우위성 지수의 값이 1이다.

## 3. 실증분석

### 3.1 자료의 구성

실증 분석을 수행하고자 본 연구가 활용하고자 하는 표본은 주택연금 가입자의 보유주택 수, 주택 면적, 월 지급금, 초기 보증료, 연 보증료, 총 대출 한도의 담보주택 관련 특성과 가입 시 본인 연령을 포함한 공변량들이며, 2007년부터 2021년까지 주택연금 누적 가입자를 활용하였으며 91,031 명을 분석하였다.


### 3.2 모형의 추정 및 분석

사건-시간 분석 모형은 결과가 발생하기까지 걸리는 시간을 분석하는 모형이며, 생존 분석이라는 이름으로 많이 활용되고 있다. 인공신경망 기반의 생존 분석 모형 최적화 성능평가분석을 위해 구체적으로 다음의 방법을 적용했다. 본 연구에서는 모형의 학습 및 검증, 평가를 실시하기 위해서 분석 데이터를 약 6:2:2의 비율로 분할을 하였는데, 이 중 학습 데이터는 58,260개, 검증 데이터는

14,565개, 그리고 평가데이터는 18,206개로 각각 구성되어 있다. 그리고 전체 자료의 80%는 인공신경망을 통해서 훈련을 행하고, 나머지 20%의 경우에는 학습된 모형에 입력 변수로 투입해 주택연금 가입자의 해지 위험 예측의 비교 및 검증을 통해 최적 모형을 최종적으로 확인했다.

SGD, RMSprop, Adam 최적화 알고리즘으로 구성된 각각의 인공신경망 학습의 수행을 위해서 담보주택 관련 특성과 가입 시, 본인 연령을 포함한 공변량을 입력층의 입력데이터로 사용하고, 결과 변수가 발생하기까지의 시간과 연금 해지를 목표 값으로 지정하였다. 이 경우 활성화함수에서 발생할 수 있는 기울기 소실에 관한 문제의 해결을 위해서 렐루(ReLU)함수를 활성화함수로 적용했다.

인공신경망의 구성 시 은닉층의 수, 활성화 함수(Activation Function), 은닉층에 존재하게 되는 노드의 수, 신경망의 초기화 기법, 최적화 등이 적절하게 최적화되지 못할 경우에는 높은 성능을 담보하기가 곤란해질 수 있다. 이같이 인공신경망의 여러 초매개변수의 가능한 모든 조합(Combination)을 통해서 최적 조합을 모색하는 것은 대단히 어려운 문제이기 때문에 높은 수준의 계산량이 요구된다고 할 수 있다. 다양한 초매개변수들 중에서 가장 직접적으로 학습과 관련이 된 최적화 알고리즘은 모형의 손실 값이 최소화가 되도록 가중치의 조정을 행하는 데 있어 가장 핵심적이면서 중요한 역할을 담당하게 된다 [14]. 동일한 구조 및 초매개변수를 갖고 있는 인공신경망이라 할지라도 그 성능은 최적화 알고리즘에 따라서 다르게 나타날 수 있기 때문에 가장 적합한 최적화 알고리즘의 탐색은 매우 중요한 부분이 된다. 이에 본 논문에서는 SGD, RMSprop, Adam 최적화 알고리즘이 인공신경망 기반의 생존 분석 모형의 예측 성능에 미치는 영향을 측정해 분석하는 연구를 수행하였다. 즉, SGD, RMSprop, Adam 최적화 알고리즘의 사용을 통해 공변량을 입력 값으로 그리고 결과 변수가 발생하기까지의 시간과 연금 해지를 목표 값으로 각각 지정한 뒤 학습 진행(Episode)에 의한 손실함수값을 계산한다.



[그림 1] 학습 성능 그래프

[Fig. 1] Performance for Train and Validation

그 결과 [그림 1]과 같이 학습과 검증 자료에 대해 비교적 안정적인 학습 그래프를 나타낸다. 검

증 자료의 경우, 학습 진행이 증가함에 따라 손실 값의 편차가 상대적으로 커지는 구간도 등장하고 큰 진폭도 형성되었지만, 결과적으로 SGD의 손실은 0.0634, Adam의 손실은 0.0674 그리고 RMSProp의 손실은 0.0677로 학습이 적정하게 수행되었다는 것을 알 수 있다. 더불어 Adam의 경우, SGD와 RMSProp보다 상대적으로 짧은 학습 진행을 보였다. 이는 운동량(Momentum)의 개념 및 적응형 방법(Adaptive Method)을 동시 적용한 Adam 최적화 알고리즘이 갖는 우수한 학습 성능 또한 확인할 수 있게 됐다 [12].

마지막으로 [표 1]에는 전통적인 통계 모형과 인공신경망 모형에 따른 우위성 지수를 살펴볼 수 있다. 주택연금 해지 위험을 예측한 결과, 인공신경망과 Adam 최적화 알고리즘을 사용한 모형이 가장 높은 예측 값을 제공하였다. 하지만 인공신경망에 SGD와 RMPPProp를 결합한 모형의 위험 예측 결과가 전통적인 콕스 비례위험모형보다 약간 낮았다. 이를 통해 최적화의 중요성과 더불어 운동량(Momentum)의 개념 및 적응형 방법(Adaptive Method)을 동시 적용한 Adam 최적화 알고리즘의 우수한 학습 성능 또한 확인할 수 있게 됐다.

[표 1] 통계 모형과 인공신경망 모형의 우위성지수 비교

[Table 1] Concordance Index for Cox Proportional Hazards and Artificial Neural Network Models

통계모형	인공신경망 모형		
콕스 비례위험모형	Adam	SGD	RMSProp
0.856	0.879	0.843	0.838

#### 4. 결론

최근 빅데이터 시대가 도래하면서 인공 신경망 모형을 포함한 기계학습모형들이 다양한 의학 영역과 유전체 연구 그리고 기업의 생존 등에 이르기까지 굉장히 광범위한 영향력을 행사하며 그 영역을 넓혀가고 있지만, 생존 분석을 기계학습에 적용한 국내 계량 금융·보험 연구들은 충분히 축적되지 못하고 있는 상황이다. 제안된 생존 분석과 인공신경망을 결합한 기법을 주택연금의 해지 예측에 적용할 경우 다음과 같은 장점이 있다. 첫째, 주택연금 가입자의 신용 점수, 금융 거래 내역, 소득 수준, 부동산 시장 동향 등 다양한 데이터를 활용하여 대출 계약의 해지 가능성을 예측하는 데 도움을 줄 수 있다. 둘째, 주택연금의 해지 위험은 시간에 따라 변화할 수 있는데 동적 인공신경망 모형을 활용하여 경제적인 변동이나 부동산 시장의 변동에 따라 대출자의 해지 가능성을 더 정확하게 예측할 수 있다. 셋째, 인공신경망은 개별 가입자의 해지 가능성을 더 정확하게 예측하기 때문에 운영기관인 주택금융공사는 개인별 맞춤형 주택연금 제도 개선 및 주택연금 위험 관리를 개선하는 데 도움을 줄 수 있다. 이처럼 인공지능의 활용 및 인식이 점차 확산되면서 향후에는 연금보험 분야로도 적용 가능성이 클 것으로 전망된다.



하지만 인공신경망의 구성 시 은닉층의 수, 활성화 함수, 은닉층에 존재하게 되는 노드의 수, 신경망의 초기화 기법, 최적화 등이 적절하게 최적화되지 못할 경우에는 높은 예측 성능을 담보하기가 곤란해질 수 있다. 이같이 인공신경망의 여러 초매개변수의 가능한 모든 조합을 통해서 최적 조합을 모색하는 것은 대단히 어려운 문제이기 때문에 높은 수준의 계산량이 요구된다고 할 수 있다. 다양한 초매개변수들 중에서 가장 직접적으로 학습과 관련이 된 최적화 알고리즘은 모형의 손실 값이 최소화되도록 가중치의 조정을 행하는 데 있어 가장 핵심적이면서 중요한 역할을 담당하게 된다 [14]. 동일한 구조 및 초매개변수를 갖고 있는 인공신경망이라 할지라도 그 성능은 최적화 알고리즘에 따라서 다르게 나타날 수 있기 때문에 가장 적합한 최적화 알고리즘의 탐색은 매우 중요한 부분이 된다.

본 연구는 주택연금 가입자의 데이터와 인공신경망 모형을 활용한 생존 분석 모형을 설계하고, 우위성 지수를 통한 판별분석 측면에서 최적화 알고리즘인 Adam, RMSProp 그리고 SGD를 비교·분석하였다. 본 연구 수행에 따른 실증 분석의 주요 결과를 요약·정리해 제시하면 다음과 같다. 첫째, 전통적인 통계 모형과 인공신경망 모형을 생존 분석에 적용하여 주택연금 가입자의 해지 예측한 결과, 인공신경망과 Adam 최적화 알고리즘을 사용한 모형이 좀 더 개선된 예측 값을 제공하였다. 이는 생존 분석에 인공신경망을 결합한 모형이 연금 가입자의 해지 예측 문제에 응용될 수 있다는 점을 확인했다. 둘째, SGD과 RMPProp과 인공신경망을 결합한 모형의 위험 예측 결과가 전통적인 콕스 비례위험모형보다 약간 낮았다. 이를 통해 최적화의 중요성과 더불어 운동량(Momentum)의 개념 및 적응형 방법(Adaptive Method)을 동시 적용한 Adam 최적화 알고리즘의 우수한 학습 성능도 또한 확인할 수 있게 됐다. 마지막으로 본 연구는 인공신경망 기법을 주택연금에 최초로 적용하였다는 점에서 의미가 있다. 향후에는 주택연금 뿐 만 아니라 다른 연금 보험 데이터에 응용할 수 있는 일반화 가능성을 보여준다.

본 연구는 이 같은 연구 성과 및 의의를 나타냄에도 불구하고 향후 후속 연구의 수행을 통해 몇 가지 보완이 필요한 부분이 있다. 본 연구 수행에 활용한 주택연금의 해지는 가입자의 사망으로 인한 해지와 중도해지로 구분되는데 주택연금제도의 질적 성장 및 제도발전을 모색하기 위한 측면에서 구분된 해지 데이터에 근거한 분석 및 예측이 필요하다. 더불어 본 연구 수행에 활용한 콕스 비례위험모형은 시간에 따라 결과 변수가 발생하는 위험함수를 계산하여 위험비를 산출하며, 시간에 관계없이 예측 인자의 위험비가 일정하다는 가정을 기반으로 한다. 이에 위험비가 시간에 따라 변화할 때도 변수와 시간 사이의 교호작용 항을 모형에 추가하여 고려한 동적 예측 모형연구가 필요하다.

## References

- [1] K. J. Choi, S. Y. Kim, H. J. Chun, “A Study on Factors Affecting Death Termination Risk of Korean Home Pension Subscribers Using the Cox-Proportional Risk Model: Focused on Warrantee of the Korean Home Pension”, *Journal of Insurance and Finance*, vol. 109, November 2022, pp. 43-70, doi: 10.23842/jif.2022.33.4.002.
- [2] H. J. Chun, “Study on reverse mortgage user’s mid-term termination inclination”, *Journal of the Korean Data And Information Science Society*, vol. 33, no. 4, July 2022, pp. 589-599, doi: 10.7465/jkdi.2022.33.4.589
- [3] K. J. Choi, H. J. Chun, “Effect and Implications of Housing Price Changes on Mid-Term Termination of Reverse Mortgage”, *Journal of Budget and Policy*, vol. 10, no. 4, December 2021, pp. 207-230, doi: 10.35525/nabo.2021.10.4.007.
- [4] K. Y. Ryu, J. S. Lee, Y. Choi, “An Analysis on Determinants of Termination of Reverse Mortgage Considering Characteristics of the Subscriber”, *Journal of Korea Planning Association*, vol. 55, no. 4, August 2020, pp. 85-94.
- [5] B. K. Kim, “Early Termination Hazard of Reverse Mortgage”, *Journal of the Korea Real Estate Analysts Association*, vol. 26, no. 2, June 2020, pp. 7-21, doi: 10.19172/KREAA.26.2.1.
- [6] Y. S. Kim, Y. M. Lee, “Survival Analysis of Korean Home Pension : A Focus on Detailed Consumer Characteristics”, *Journal of the Korea Real Estate Analysts Association*, vol. 26, no. 4, December 2020, pp. 41-69, doi: 10.19172/KREAA.26.4.3.
- [7] Y. J. Jeon, S. J. Yoo, “Effects of the Characteristics of the JooTeakYeonKeum Contract on Its Termination”, *Korea Real Estate Review*, vol. 28, no. 1, March 2018, pp. 115-130.
- [8] G. S. Kim, S. W. Shin, “A Study on the Termination Hazard of the JooTeakYeonKeum”, *Journal of The Residential Environment Institute of Korea*, vol. 12, no. 4, November 2014, pp. 241-252.
- [9] S. J. Yoo, M. J. Noh, “A Study on the Determinants of the Termination of Reverse Mortgage Contract”, *Journal of the Korea Real Estate Analysts Association*, vol. 19, no. 2, June 2013, pp. 57-75.
- [10] M. Jiang, C. L. Miller, “Termination Risk of Reverse Mortgages”, *International Real Estate Review*, vol. 22, no. 2, Summer 2019, pp. 169-196.
- [11] W. S. Lee, H. J. Chun, “A deep learning analysis of the Chinese Yuan’s volatility in the onshore and offshore markets”, *Journal of the Korean Data And Information Science Society*, vol. 27, no. 2, March 2016, pp. 327-335, doi: 10.7465/jkdi.2016.27.2.327.
- [12] W. S. Lee, “Performance Evaluation of Portfolio using a Deep Q-Networks”, *Journal of Next-generation Convergence Information Services Technology*, vol. 10, no. 4, August 2021, pp. 459-470, doi: 10.29056/jncist.2021.08.10.
- [13] H. Y. Jang, E. K. Yoo, H. J. Kim, “Optimal Algorithm and Number of Neurons in Deep Learning”, *Journal of Digital Convergence*, vol. 20, no. 4, April 2022, pp. 389-396, doi: 10.14400/JDC.2022.20.4.389.
- [14] G. H. Joo, C. H. Park, H. S. Im, “Performance Evaluation of Machine Learning Optimizers”, *Journal of*

IKEEE, vol. 24, no. 3, December 2020, pp. 766-776, doi: 10.7471/ikeee.2020.24.3.766.

- [15] F. E. Harrell, R. M. Jr. Califf, D. B. Pryor, K. L. Lee, R. A. Rosati, "Evaluating the yield of medical tests", *The Journal of the American Medical Association*, vol. 247, no. 18, May 1982, pp. 2543-2546, doi: 10.1001/jama.1982.03320430047030.