

<http://dx.doi.org/10.17703/JCCT.2023.9.2.533>

JCCT 2023-3-66

## 인공신경망 모형을 활용한 미술품 경매에 대한 COVID-19의 파급효과 분석

### Analysis of the Ripple Effect of COVID-19 on Art Auction Using Artificial Neural Network

이지인\*, 송정석\*\*

Lee, Ji In\* and Song, Jeong Seok\*\*

**요약** 본 연구에서는 한국 미술품 데이터를 통해 COVID-19의 미술 시장 파급 효과를 분석하고, 전통적인 통계 방법인 헤도닉 모형과 인공신경망의 성능을  $R^2$ 와 RMSE로 비교 분석하며 미술품 가격을 형성하고 있는 요인의 중요도에 대해 명시적으로 분석해 본다. 헤도닉 모형과 인공신경망의 실증 분석에 사용된 데이터는 2015-2021년의 거래된 한국 미술품 가격 데이터로 총 14,639개를 수집하였다. 각 모형에 적용된 변수는 기존 선행 연구에서 사용되었던 가격형성요인을 참고하여 두 모형 동일하게 적용하였다. 그 결과 COVID-19가 처음 발생하였던 연도인 2020년에는 미술품 가격이 하락하였으나 2021년에는 미술품 가격이 상승한 것으로 나타났다. 헤도닉 모형과 인공신경망의 성능을 비교하였을 때 인공신경망의  $R^2$ 는 0.764, RMSE는 0.076, 헤도닉 모형의  $R^2$ 는 0.677, RMSE는 1.071로 인공신경망의 성능이 우수한 것으로 나타났다. 또한 중요도를 명시적으로 확인하였을 때 작품적 요인이 크게 작용하였다는 점에 주목할 만하다. 예측하지 못한 상황적 변수로 미술시장이 급변하는 시점에서 본 연구의 결과는 효율적인 미술품 가격 모형을 제시해 줄 것이라 생각한다.

**주요어** : 인공신경망, 헤도닉 모형, 미술품 가격, 예측, COVID-19

**Abstract** This study explores the influence of the COVID-19 pandemic on the Korean art market and contrasts the classic hedonic method of art price prediction with the Artificial Neural Network technique. The empirical analysis of this paper utilizes 14,639 observations of Korean art auction data from 2015 to 2021. There are three types of variables in this study: artist-related, artwork-related, and sales-related. Previous studies have suggested that these three types of variables influence art prices. The empirical findings in this research are in twofold. First, in terms of RMSE and  $R^2$ , the Artificial Neural Network outperforms the hedonic model. Both techniques discover that sales and artwork variables have a greater impact than artist-related attributes. Second, when the primary factors of art price are controlled, Korean art prices are found to fall dramatically in 2020, shortly following the onset of COVID-19, but to rebound in 2021. The main lesson in this study is that the Artificial Neural Network enhances art price prediction and reduces information asymmetry in the Korean art market even in the face of unanticipated turmoil such as the COVID-19 outbreak.

**Key words** : Artificial Neural Network, Hedonic Price Model, Art Price, Prediction, COVID-19

\*준회원, 중앙대학교 문화예술경영학과 석박통합과정 (제1저자) Received: January 30, 2023 / Revised: March 1, 2023

\*\*정회원, 중앙대학교 경제학과 교수 (교신저자)

Accepted: March 9, 2023

접수일: 2023년 1월 30일, 수정완료일: 2023년 3월 1일

\*\*Corresponding Author: jssong@cau.ac.kr

게재확정일: 2023년 3월 9일

Dept. of Economics, Chung-Ang Univ, Korea

## I. 서 론

한국의 미술품 경매 시장은 2021년 상반기 약 1,448억 원의 낙찰총액을 달성하면서 COVID-19의 팬데믹 상황의 위기를 빠르게 대처하여 최근 5년 동안의 상반기 통계 중에서 가장 높은 낙찰총액을 달성했다. 또한 미술품의 소유권을 다수의 사람들이 공동으로 구매하는 크라우드 펀딩의 새로운 거래 방식도 등장하여 현재 보조적인 투자수단으로 각광받고 있다. 그리고 2021년 3월, 국내에서 고유한 인식 값을 부여한 가상 자산인 NTF(Non-Fungible Token) 도입을 처음으로 시도한 마리킴(Mari Kim)의 <Missing and found>(2021) 작품이 최초 5,000만 원에서 시작해 경합 후, 약 6억 원에 낙찰되는 등, 미술품은 투자 수익률을 기대할 수 있는 투자수단으로써 이목이 쏠리고 있다.

새로운 미술품 거래 양상이 등장하더라도 대량으로 거래되는 주식과 달리 미술품은 희소성이 있고 재판매가 이루어지기까지의 기간이 오래 걸리는 비유동성의 독특한 특성을 지니고 있기에 논리적 패턴을 설정하는데 어려움이 있다[1]. 그럼에도 불구하고 미술품 가격에 관한 연구들이 꾸준히 이루어져 왔는데 이는 대부분 헤도닉 모형과 반복판매모형을 활용한 연구들이다.

최근 여러 분야에서 예측에 관한 연구에 인공지능이 적용되고 있다. 특히 본 연구에서 사용한 인공신경망(Artificial Neural Network)은 주택 가격[2, 3], 금융 분야에서의 환율[4], 주가[5] 및 기상 예측[6, 7] 등의 다양한 분야에 활용되고 있다. 이처럼 인공신경망의 주요한 적용 분야는 예측에 관련된 연구이며[8], 전통적인 통계 기법에 대한 유용한 대안으로 평가받고 있다[9, 10]. 그러나 미술품 가격 예측 연구에 인공신경망을 적용한 연구는 드물다. 미술품 가격 예측에 인공신경망을 적용한다면 방대한 양의 데이터를 바탕으로 빠른 분석이 가능하기에 효율적인 측면에서 유리하여 그 의미가 있다.

본 연구에서는 2015년부터 2021년까지의 미술품 경매 데이터 총 14,639개를 바탕으로 전통적인 통계 방법인 헤도닉 모형과 인공신경망을 활용하여 미술품 가격 예측 모형을 구상하고, 각 모형의 성능을 비교 분석하였다. 모형의 정확도는  $R^2$ 와 RMSE(Root Mean Square Error)를 기준으로 평가하였다. 인공신경망을 적용하여 미술품 가격 예측의 정확도를 향상시킬 수 있다면 미술품 가격 예측의 한계를 극복하여 미술시장의

활성화를 도모할 수 있을 것이라 기대한다.

본 연구의 구성은 다음과 같다. 제2장에서는 미술품 가격에 대한 연구 및 인공신경망을 적용한 다양한 분야의 선행연구들을 살펴보고 제3장에서는 헤도닉 모형과 ANN의 구조를 이론적으로 소개하며, 제4장에서는 수집한 데이터를 이용하여 헤도닉 모형 추정 결과와 ANN의 성능의 결과를 각각 제시하여 두 모형의 성능을 비교 분석하고 미술품 시장에서의 COVID-19의 파급효과에 대해 분석하며 끝으로 제5장에서 연구의 결론과 시사점을 제시하고자 한다.

## II. 선행 연구

### 1. 미술품 투자수익률 분석 선행연구

미술품 가격 지수 산출 및 투자 수익률 분석에 대한 다양한 연구들이 진행되어왔다. 대부분의 연구에서 미술품의 잠재되어있는 특성들을 변수로 규정하고 선형 회귀식을 도출하는 헤도닉 가격 모형을 기반으로 이루어지거나 반복판매모형을 사용했다. 그 결과 연구마다 미술품이 투자재로서 매력적인가에 대한 의견이 상이하다.

Anderson(1974)은 1780년부터 1970년의 반복 판매된 미술품 가격 변동을 바탕으로 수익률을 산출한 결과 4.9%로 주식 상승률의 절반 정도되는 수준이었지만 인상주의 작품의 경우 수익률이 11%로 장르마다 수익률이 상이하게 나타나는 것을 확인할 수 있었다[11]. Baumol(1986)의 연구에서는 예측이 어려운 미술품 시장에서 미술품을 구매한다는 것에 대해 부정적인 시각을 제시하였다. 1652년부터 1961년 반복적으로 판매된 미술품 가격 데이터를 이용하여 수익률을 분석하였을 때 0.55%에 불과하였으며 이는 당시 국공채 수익률인 2.5%에 미치지 못하는 것으로 나타났다[12]. 또한 Pesando(1993)의 연구에서는 회화 작품이 아닌 판화 작품을 토대로 평균 수익률을 분석한 결과 1.51%로 미술품이 투자재로써 수익이 좋지 못함을 발견하였다[13]. Marilena et al(1999)는 1987년부터 1995년 동안 1,446개의 반복판매 데이터를 사용하여 미술품 투자의 성과를 분석하였을 때 기간별로 수익률이 상이했다. 1987-1993년에 판매된 작품의 수익률은 국채, 금과 같은 대체 투자 수단에 비해 좋은 성과를 보이고, 1992-1995년의 판매된 작품의 수익률은 저조한 것으로 나타났다[14].

Goetzmann(1993)에서는 Marilena의 연구와 유사하게 기간을 조정하여 미술품 투자 수익률을 분석하였다. 그 결과 1900-1986년의 수익률이 17.5%로 높은 것으로 나타났다. 그러나 미술품 수익률이 주식의 수익률과 높은 상관관계를 가지는 것으로 나타나 대체 수단으로는 불충분하다고 주장했다[15]. Chanel et al(1994, 1995, 1996)의 연구에서 반복판매모형과 헤도닉 모형을 활용하여 미술품 가격 지수와 금융시장의 지수를 분석한 결과 미술품 가격에 대한 장기적인 예측이 어렵다고 결론지었다[16, 17, 18, 26].

## 2. 인공지능경망을 활용한 선행연구

인공지능경망을 미술품 가격 예측에 적용한 연구는 드물지만 여러 분야에 걸쳐 예측하는 연구에 응용되어왔다. Visit et al(2004)은 뉴질랜드 크라이스트처치에 있는 주택 데이터 200개를 통해 헤도닉 모형과 인공지능경망의 성능을 비교 분석했다. 종속변수인 가격에는 세미 로그를 취하였고 와 RMSE로 성능을 비교한 결과 인공지능경망의 성능이 더 우수한 것으로 나타났다[3]. H.A.C.K et al(2013)은 콜롬보 옥션에서 차(tea)의 가격 예측을 Time Series Regression과 인공지능경망으로 분석했다. 인공지능경망의 주요 장점으로 기본 모델에 대한 가설을 가질 필요가 없다는 점을 밝히며 각 모델의 성능을 MAPE(Mean Absolute Percentage Error), MSE(Mean Square Erroe),  $R^2$ 로 성능을 확인하였다. 그 결과 인공지능경망의 경우 설명력이 96.84%로 매우 우수한 성능을 보이는 것으로 나타났다[19]. Ibrahim et al(2019)는 핸드폰 가격에 영향을 미치는 요소를 배터리 전원, CPU 클럭 속도, 듀얼심 지원 여부 등으로 설정하여 인공지능경망을 활용하여 핸드폰 가격을 예측하였다. 모형의 성능은 결정계수가 96.3%로 정확하게 예측을 하는 것으로 나타났다[20]. Hossein et al(2015)는 금 가격을 예측하기 위해 인공지능경망과 ARIMA 모델을 비교하였고 인공지능경망의 설명력은 0.967로 ARIMA 모델의 예측력을 능가하는 것으로 나타났고 금 가격을 모델링함에 있어서 인공지능경망이 강력한 도구임을 제시하였다[21]. 인공지능경망은 가격을 예측하는 분야 외에도 금융 분야[4, 5], 기상 예측[6, 7], 등 다각도로 활용되고 있다.

미술품은 미술품이 가지고 있는 독특한 특성으로 인해 시장 가격 해석에 더 많은 주의를 요한다[22]. 본 연

구에서는 인공지능경망을 활용하여 한국 미술품 가격 예측이 가능한지 그 여부를 검토하고자 한다. 따라서 본 연구에서는 한국의 경매에서 거래된 2015년부터 2021년 상반기까지의 총 25명의 작가의 미술품 데이터를 활용하여 헤도닉 모형과 인공지능경망의 성능을 비교 분석하고 COVID-19의 한국 미술품 경매시장 파급효과를 분석해 보고자 한다.

## III. 연구 모형

### 1. 헤도닉 모형

헤도닉 모형은 미술품의 가치를 추정하는 데 널리 사용되어왔다. 헤도닉 모형은 미술품 거래는 미술품 내의 속성 묶음으로 거래한다고 가정한다.

Lancaster(1966)은 상품 거래는 상품을 구성하고 있는 속성의 거래이기 때문에 가격 연구에서는 속성을 고려해야 한다고 제안하였다[23]. 미술품 가격의 속성은 크게 작품 요인, 작가 요인, 판매 요인으로 구분된다. 작품 요인에는 작품의 크기, 바탕 재료, 재료 등 작품 자체의 특징으로 구성된다. 작가 요인은 작가의 생존 여부, 나이, 명성 등과 같이 작가의 특징으로 정의된다. 마지막으로 판매 요인은 작품이 판매되는 장소, 경매 회사, 판매 시기 등의 변수를 포함한다[24]. 헤도닉 모형은 이렇게 설정된 다양한 속성과 미술품 가격 간의 관계를 결정한다. 미술품의 속성을 독립변수로 미술품 가격을 종속변수로 하여 선형 방정식을 통해 추정한다.

$$\ln p_i = \alpha + \sum_{i=1}^p \beta_i X_i + \epsilon \quad (1)$$

위의 방정식에서  $X_i$ 는 미술품의 속성을 나타내는 독립 변수로, 총  $p$ 개의 변수를 통합한다.  $\ln p_i$ 는 자연 로그를 취한 미술품 가격을 나타내며 종속변수이다. 이를 추정하는 과정에서 선형 방정식에 대한 오차 제곱합을 최소화하는 최소 자승법의 접근법을 사용한다.

헤도닉 모형은 미술품 가격에 관련된 연구에 꾸준히 적용되어 왔다. 그러나 다중 공선성의 문제가 있을 수 있으며 비선형 회귀로 추정할 수 없다는 단점이 있다. 헤도닉 모형의 단점을 보완하기 위한 해결책으로 인공지능이 주목받고 있다. 인공지능은 미술품 가격의 데이터와 같이 대량의, 높은 분산의 데이터에 대한 평가에 더 유리하기 때문이다.

## 2. 인공신경망(Artificial Neural Network)

인공신경망(Artificial Neural Network; ANN)은 사람의 신경세포의 구조를 차용하여 만든 구조인 Perceptron이 여러 개 연결되어 만들어진 것이다. Perceptron의 구조는 아래 그림과 같다. 입력이  $X_i$ 부터  $X_n$ 까지 일 때, 각각의 가중치를 곱하여 더한 값에 편향도 더하여  $s$ 의 값을 얻는다. 해당 값을 활성화 함수에 입력으로 넣어 최종적인 출력을 얻게 된다.




그림 1. 퍼셉트론 구조  
Figure 1. Perceptron Structure

$$S = \sum_{i=1}^N w_i X_i + w_o \quad (2)$$

$$h(\chi) = \sigma\left(\sum_{i=1}^N w_i x_i + w_o\right) \quad (3)$$

인공신경망은 서로 연결된 노드의 3개의 계층으로 구성되어 있다. 첫 번째 계층은 예측이 이루어지는 변수를 입력하는 “Input Layer”이다. 두 번째는 “Hidden Layer”로 해당 노드에 여러 개의 Layer로 구성되어 있을 경우 Deep Neural Network(DNN)이라고 부른다.  $X$ 에 입력 값을 넣으면 Feed-Forward 과정을 거쳐서 출력을 내게 된다. 이후 실제 값과 예측 값의 차이인 오차를 최소화하기 위해 다시 거꾸로 네트워크를 돌려 가중치를 업데이트한다. 이를 “Back-Propagation”이라고 부른다. 이 과정을 여러 번 반복하면 오차가 점점 감소되고 정확한 예측을 할 수 있게 된다. 마지막 계층은 예측된 값이 도출되는 “Output Layer”이다.




그림 2. 심층 신경망 구조  
Figure 2. Deep Neural Network Structure

인공신경망의 back propagation에 사용된 방식은 gradient descent algorithm이다. 이는 식(4)와 같이 학습률을 설정해두면 그에 맞춰 가중치를 조정하며 cost function인 오차가 최소가 되도록 하는 점을 찾는 것이다.




그림 3. 경사하강법 알고리즘  
Figure 3. Gradient Descent Algorithm

$$\theta_j = \theta_j - \alpha \cdot \frac{\partial}{\partial \theta_j} J(\theta) \quad (4)$$

인공신경망은 변수들의 인과관계를 구체적인 수치로 식별하지 못하는 한계점인 “블랙박스”를 가지고 있다. 그럼에도 불구하고 대량의 큰 분산의 데이터와 선형의 수식으로 표현되기 어려운 비선형 관계를 효과적으로 예측할 수 있기에 널리 적용되고 있다. 따라서 미술품의 특성상 선형 함수가 이를 잘 설명하는 것은 아니기에 인공신경망이 전통적인 통계 도구에 비해 유용할 것을 예상할 수 있다. 따라서 우리는 인공신경망에 의해 예측된 가격이 실제 가격을 얼마나 잘 예측하였는지 검증하고자 한다.

## IV. 실증 분석

### 1. 연구 데이터와 방법론

본 연구의 활용된 데이터는 2015년부터 2021년 상반기의 한국의 경매회사를 통해 거래된 그림의 데이터 총 14,639개의 데이터를 활용하였다. 해당 데이터는 작가별 낙찰 건수 순위 25위의 작가의 거래 데이터를 사용하였다. 상위 낙찰 건수의 작가 데이터를 사용한 이유는 판매된 작품의 수가 많을수록 인공신경망의 분석에 더 적합할 것이라고 예상했기 때문이다.

본 연구에서 사용한 변수들은 기존 미술품 가격 연구[24]에서 활용된 변수들을 참고하여 작가 요인, 작품 요인, 판매 요인 총 세 가지로 나누어보았다. 작가적 요인의 변수로는 국적과 사망 여부의 변수를 사용하였다.

대부분 한국작가이지만 25명 중 2명은 일본 작가로 총 14,639개의 작품 데이터 중 1,146개의 데이터는 일본 작가의 데이터이다. 또한 사망하였을 때 작품의 가격이 상승할 것이라는 “사망 효과[25]”가 본 연구의 데이터에도 적용이 되는지 확인해 보기 위해 사망 여부의 변수를 설정하였다.

작품 요인으로는 장르와 재료, 크기로 나누었다. 선행 연구에서 주로 바탕 재료와 재료를 구분하여 변수를 설정하였지만 본 연구에서는 한국화의 경우 한국의 종이에 한국의 재료를 사용하는 경우가 많기에 다중공선성의 문제가 있을 것을 예상하여 재료만을 변수로 설정하였다.

판매 요인으로는 판매가 이루어지는 옥션, 경매 방식을 설정하였다. 한국의 경매 회사는 2022년 기준 총 9개이며 그중 상장한 기업으로는 서울옥션과 K옥션이다. 본 데이터에서 서울옥션에서 거래된 작품은 총 2,946개, K옥션에서 거래된 작품의 수는 6,625개로 이 두 개의 회사를 제외한 나머지 옥션에서 거래된 작품의 수는 5,068개로 약 34.6%이다. 따라서 본 연구에서는 서울옥션과 K옥션, 그 외의 옥션으로 변수를 설정하였다. 경매 방식은 오프라인 경매, 온라인 경매, 홍콩에서 열린 해외 경매의 변수로 나누었다.

연도 변수는 작품이 거래된 날짜로 2015-2020으로 구분 지어 더미 변수화하였다. 연도별 더미 변수에서는 2015년을 기준 변수로 설정하였다. 따라서 본 연구에서는 Covid-19 발생 이전인 2015-2019와 발생 이후인 2020-2021를 비교하여 Covid가 한국 미술품 시장에 어떠한 파급 효과를 일으켰는지 확인해 보고자 한다. 마지막으로 본 논문은 종속변수인 미술품 가격에만 로그를 씌우는 세미 로그 모델을 채택했다.

변수 총 30개로 헤도닉 모형과 인공신경망을 실행하였다. 헤도닉 모형에서 기준 변수를 재료 변수에서는 수묵채색, 경매 회사 변수에서는 서울옥션, K옥션을 제외한 그 외의 경매 회사, 판매연도는 2015년, 경매 방식에서는 온라인 경매 방식으로 채택하였다. 따라서 4가지의 기준 변수를 제외 후 헤도닉 모형을 실시하였다.

표 1. 변수 설정

Table 1. Description of variables

Variable	Definition	Data type
Dependent variable	price	Continuous
Artist	Nationality	Korea = 1

		Or not = 0	
	Death	Death = 1 Or not = 0	“
Art Work	width	cm	Continuous
	length	cm	“
	printing	Printing = 1 Painting = 0	Categorical
	Indianink	Indianink=1 Or not = 0	“
	Oriental color	Orientalcolor=1 Or not = 0	“
	Oil	Oil = 1 Or not = 0	“
	Acrylic	Acrylic = 1 Or not = 0	“
	Gouache	Gouache = 1 Or not = 0	“
	Charcoal	Charcoal = 1 Or not = 0	“
	Pencil	Pencil = 1 Or not = 0	“
	Pen	Pen = 1 Or not = 0	“
	Water	Water = 1 Or not = 0	“
Art Work	Mixed	Mixed = 1 Or not = 0	Categorical
	Etc	Etc = 1 Or not = 0	“
Sales	Seoul Auction	Seoul = 1 Or not = 0	Categorical
	K Auction	K = 1 Or not = 0	“
	Auction Etc	Etc = 1 Or not = 0	“
	2015	2015 = 1 Or not = 0	“
	2016	2016 = 1 Or not = 0	“
	2017	2017 = 1 Or not = 0	“
	2018	2018 = 1 Or not = 0	“
	2019	2019 = 1 Or not = 0	“
	2020	2020 = 1 Or not = 0	“
	2021	2021 = 1 Or not = 0	“
	offline	offline = 1 Or not = 0	“
	online	online = 1 Or not = 0	“
	oversea	oversea = 1 Or not = 0	“

인공신경망은 실행하기 전에 모든 변수를 정규화하였다. 은닉층은 총 5개로 각각 25, 20, 15, 10, 5로 점차

줄어드는 노드로 설정하였다. 인공신경망에 활용한 활성화 함수는 -1과 1사이의 값을 예측하기 위한 활성화 함수인 Tahn sigmoid 함수를 채택하였다. 해당 데이터를 2개의 세트로 나누어 한 세트는 훈련에 사용하고 나머지는 검증하기 위해 활용하였다. 각각의 세트 비율은 전체 데이터의 70%, 30%로 설정하였다. 따라서 훈련하기 위해 사용된 데이터는 10,247개, 테스트하기 위해 사용된 데이터는 4,392개이다. 인공신경망의 표본 분석의 관행에 따라 실험할 때마다 무작위로 데이터를 나누어 실험하였다.

각 모형의 성능의 정확도는  $R^2$ 와 RMSE(Root Mean Square Error)로 판단하였다.  $R^2$ 는 높을수록, 또 RMSE가 낮을수록 모형의 예측도가 더 높은 것으로 성능이 우수하다고 판단한다.

$$R^2 = 1 - \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (5)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (6)$$

위의 식에서  $y_i$ 는 실제 미술품 가격을 의미하고  $\hat{y}_i$ 는 예측된 미술품 가격이고 n은 미술품 개수를 의미한다.

2. 실증분석 결과

1) 헤도닉모형 결과

본 연구에서는 2015년부터 2021년 상반기의 한국의 경매 회사를 통해 거래된 그림의 데이터 총 14,639개의 데이터를 활용하여 COVID -19의 파급효과를 확인하고자 헤도닉 모형과 Artificial Neural Network(ANN)을 실시하였다. 다음 표 2는 연도별 헤도닉 모형 검증 결과이다.

표 2. 헤도닉 모형 결과  
Table 2. Result of the Hedonic model

variable	Coef	Robust Std.Er r	t	P> t
Nationality ***	-.579	.038	-15.374	0.000
Death ***	-.340	.022	-15.554	0.000
width***	.001	.000	10.809	0.000
length***	.003	.000	19.172	0.000
printing ***	-.638	.026	-24.554	0.000
Indian Ink	-.031	.029	-1.063	0.288
Oil ***	1.759	.035	50.392	0.000

Acrylic ***	1.594	.061	26.044	0.000
Gouache ***	1.147	.090	12.707	0.000
Charcoal ***	.621	.169	3.674	0.000
Pencil ***	.827	.117	7.041	0.000
Pen *	.155	.080	1.941	0.052
Water ***	1.417	.039	36.144	0.000
Mixed ***	1.670	.074	22.491	0.000
Etc ***	.758	.097	7.780	0.000
Seoul Auction ***	.989	.027	36.696	0.000
K Auction ***	.811	.021	38.202	0.000
2016	.040	.035	1.148	0.251
2017	-.024	.033	-.719	0.472
2018	-.004	.034	-.011	0.912
2019	-.024	.034	-.072	0.472
2020 ***	-.133	.033	-3.993	0.000
2021 ***	.292	.036	8.198	0.000
Offline ***	1.472	.022	65.790	0.000
Oversea ***	2.312	.056	41.464	0.000
$R^2 = .677$ F = 1224.427 RMSE = 1.07098				
*는 10% 유의수준, **은 5% 유의수준, ***은 1% 유의수준에서 통계적으로 유의미함을 의미함.				

본 연구의 헤도닉 모형 추정 결과는  $R^2$ 가 0.677로 나타나 회귀식이 잘 추정되었음을 알 수 있다. 대부분의 독립변수들이 유의하지만, 먹과 연도 더미 변수 중 2016-2019는 유의하지 않은 것으로 나타났다. 헤도닉 모형에 의해 추정된 한국 미술품에 영향을 미치는 요인에 대한 분석은 다음과 같다.

첫 번째, 작가 요인에서는 한국작가의 작품 가격보다 외국 작가의 작품 가격이 높게 책정되는 것으로 나타났다. 또한 사망한 작가의 작품 가격 보다 현존하는 작가의 작품 가격이 더 높은 것으로 보아 본 연구에 활용된 데이터에서는 작가가 사망할 시 희소성이 높아져 작품 가격이 올라가는 “Death Effect”는 존재하지 않은 것으로 나타났다.

두 번째, 작품 요인에서 작품의 크기가 클수록 한국 미술품의 가격은 높아지는 것으로 나타났다. 재료의 측면에서는 수묵채색을 기준 변수로 두었다. 그 결과 먹만 유의미하지 않은 결과가 나왔다. 판화를 제외한 그 외의 재료 모두 수묵채색보다 높은 가격으로 책정되는 것을 확인할 수 있다. 이를 통해 동양화 재료보다 서양화의 재료인 오일, 아크릴, 과슈, 수채화, 건식재료인 연필, 차콜을 활용한 그림의 가격이 더 높다는 것으로 나타났다. 여러 재료 중에서 특히 유화 작품의 가격이 가장 높게 책정되는 것으로 나타났다.

세 번째, 판매 요인은 한국의 상장한 옥션을 제외한

나머지 경매 회사들을 기준 변수로 두었을 때, 상당한 경매 회사인 서울옥션과 K 옥션에서 판매된 작품의 가격이 더 높은 것으로 나타났다. 특히 2021년 10월 기준 한국에서 거래된 미술품 낙찰총액의 가장 높은 비중을 차지한 서울옥션에서 거래가 이루어질 때 가격이 가장 높은 것으로 확인되었다. 거래가 이루어지는 방식에서는 온라인 거래를 기준 변수로 설정하였을 때 오프라인과 해외 경매에서 거래되는 작품의 가격이 더 높은 것으로 나타났다. 이는 실제 경매가 이루어지는 경매장의 분위기, 직접 그림을 보고 구매하지 못한다는 온라인 경매의 단점에 의해 이러한 결과가 나온 것이라 판단된다.

마지막으로 COVID-19의 미술품 경매시장의 파급 효과를 살펴보고자 한다. 2015년을 기준 변수로 COVID-19가 발발하지 않았던 시기의 연도 더미 변수는 모두 유의하지 않은 것으로 나타났다. 반면 COVID-19가 발생한 2020년과 2021년은 유의미한 결과를 확인할 수 있었다. COVID-19로 인해 미술계 전체가 휘청거렸던 시기인 2020년에 거래된 미술품 낙찰가는 하락한 것으로 나타났다. 그러나 장기화되고 있는 팬데믹 상황에 발 빠르게 대처하여 2021년에는 2020년 하락한 것 이상으로 미술품 낙찰가가 상승한 것으로 나타났다.

## 2) 인공지능경망 결과

본 연구에서는 헤도닉 모형과 인공지능경망의 성능을 비교하기 위해 동일한 데이터를 활용하여 인공지능경망으로 실증분석하였다. 총 14639개의 데이터 중 70%인 10,247개의 데이터는 훈련에 사용하였다. 이때 표본은 무작위로 선정하였다. 이를 통해 모델의 출력값을 실제 출력값과 비교를 한 뒤, 역전파를 통해 예측 오류를 줄이기 위해 시도하였다. 오류가 가장 적어진 모델에 30%인 4,392개의 데이터로 검증을 시도하였다. 본 논문의 각 모델의 성능은  $R^2$ 와 RMSE의 척도로 평가된다. 그 결과 전체 데이터를 사용한 인공지능경망의 결과는 다음과 같다.

표 3. 인공지능경망 결과

Table 3. Artificial Neural Network Results

	N	$R^2$	RMSE
Training(70%)	10,247	.7730	.0747
Testing(30%)	4,392	.7417	.0788
Total	14,639	.7637	.0760

N은 데이터 세트의 개수를 의미하고  $R^2$ 는 종속변수의 변동성을 독립변수로 설명할 수 있는 정도를 나타낸다. 이는 1에 가까울수록 성능이 높은 것으로 판단한다. RMSE는 모형에서 예측한 값과 관측된 값 사이의 차이를 계산한다. 따라서 RMSE는 작을수록 성능이 우수한 것으로 간주 된다.

본 연구에서 사용된 훈련 데이터와 테스트 데이터의 RMSE의 차이가 많이 나지 않기에 오버 피팅의 문제점을 없는 것으로 확인되었다. 인공지능경망의 경우 약 76.3% 예측하는 것으로 나타났다. 또한 RMSE는 0.076으로 정확도가 높다. 본 연구에서 헤도닉 모형의 성능은  $R^2$ 가 0.677, RMSE는 1.07098로 ANN의 성능이 더 우수한 것으로 나타났다.




그림 4. 실제 데이터와 예측값 비교

Figure 4. Comparison of Actual Data and Prediction Results

그림 4는 각 값들의 분포를 가지적으로 보여주는 그래프로 파란색 가위표 마크들은 훈련하기 위해 사용된 데이터 세트이고, 주황색 원형 마크들은 훈련된 모형을 검증하기 위해 사용된 데이터 세트이다. 가로 축이 실제 값, 세로 축이 예측 값을 나타내는 것으로 직선에 근접할수록 예측력이 우수함을 의미하는데, 본 연구의 결과는 예측이 상당히 정확한 것을 보여주고 있으며 중간 가격대의 영역에 비해 가격이 너무 낮은 영역에서는 상대적으로 예측을 더 높은 가격으로 하고, 가격이 너무 높은 영역에서는 상대적으로 예측을 더 낮은 가격으로




그림 5. 반복 횟수 증가에 따른 오차 감소

Figure 5. Error Decay with Increasing Epochs

로 한다는 것을 관찰할 수 있었다.

그림 5의 Epoch는 전체 데이터를 반복 학습한 횟수를 의미한다. 반복 학습을 많이 할수록 오버피팅의 문제가 발생하기도 한다. 본 연구의 데이터는 총 17번 반복 학습을 한 것 중에 반복을 11번 했을 때 오차가 가장 적어 최적임을 알 수 있다.




그림 6. 훈련 및 검증 데이터세트에 대한 오차 히스토그램  
Figure 6. Error Histogram with Training and Validation Dataset

그림 6의 가로축은 실제값에서 예측값을 뺀 값을 의미한다. 오렌지색의 세로줄은 에러가 0일 때를 의미하는 Zero Error 선이다. 이 선을 기준으로 어느 한쪽으로 편향되지 않고 거의 정규분포의 모습을 띄고 있고 선 주변으로 에러 값들의 빈도가 높게 분포하고 있기에 모형이 정확하게 예측하고 있다는 것을 보여주는 증거이다. Zero Error 선을 기준으로 왼쪽은 실제 가격보다 더 높게 예측된 데이터들이며 오른쪽은 실제 가격보다 더

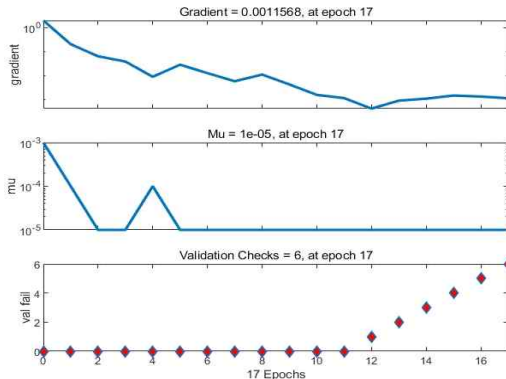


그림 7. 훈련 과정 그래프 (위) 경사 수렴, (가운데) 학습을 수렴, (아래) 유효성 검증 실패  
Figure 7. Training Progress (above) Gradient Convergence Plot, (mid) Learning Rate Convergence Plot, (bottom) Validation Fail Plot

낮게 예측된 데이터들이다.

그림 7의 가장 위쪽에 위치한 그래프는 에러 함수의 최솟값을 찾아가는 것을 가지적으로 보여주는 그래프이며 기울기를 의미하는 미분계수가 0이 되는 것을 찾는 과정과 같다. 다음 그래프는 Levenberg Marquardt 최적화 알고리즘에서 사용되는 파라미터인 Mu의 변화를 보여주는 그래프이다. 기울기가 0이 되는 점을 찾아가 갈 때 급진적으로 변화하지 않도록 어느 정도 값이 작아져서 수렴되면 멈추는 것을 보여주고 있다. 마지막 그래프는 실제값과 예측값의 오차가 없으면 Validation Fail이 1씩 늘어나게 되는데 본 연구의 모형에서는 Validation fail이 6일 때 전체 데이터 반복 학습이 종료 되도록 설정이 되어있다. 그래프를 살펴보면 Validation fail이 6, Epochs일 때 17이 되어 종료되었음을 알 수 있다.

다만 인공지능망의 내재적인 특성인 “블랙박스”의 한계점으로 변수들 간의 모든 인과관계를 구체적인 수치로 식별할 수 없다. 하지만 본 연구에서는 각 변수가 가격에 미치는 영향의 정도를 명시적으로 파악하기 위한 시도를 하였다. 한국 미술품 가격에 영향을 주는 변수를 확인하기 위해 각 변수를 누락하면서  $R^2$ 와 RMSE의 변화를 보고자 하였다. 각 모델의 결과는 다음 표 4와 같다.

표 4. 각 변수별 중요도 평가  
Table 4. Importance Test of individual variable

	Training	Test	Total	
Entire model	$R^2$	.7730	.7417	.7637
	RMSE	.0747	.0788	.0760
Non COVID-19 model(2015-2019)	$R^2$	.7842	.7425	.7715
	RMSE	.0723	.0801	.0746
COVID-19 model(2020-2021)	$R^2$	.7818	.7465	.7715
	RMSE	.0734	.0776	.0747
Except death model	$R^2$	.7627	.7270	.7523
	RMSE	.0771	.0793	.0778
Except nation model	$R^2$	.7640	.7259	.7527
	RMSE	.0764	.0807	.0777
Except Artist Variables model	$R^2$	.7450	.7052	.7329
	RMSE	.0790	.0848	.0808
Except Artwork Size model	$R^2$	.7244	.7088	.7196
	RMSE	.0821	.0842	.0827
Except Artwork Material model	$R^2$	.6610	.6231	.6495
	RMSE	.0909	.0963	.0925
Except Artwork Variables model	$R^2$	.5860	.5757	.5829
	RMSE	.1008	.1017	.1011
Except Auction	$R^2$	.7195	.6997	.7133



model	RMSE	.0822	.0869	.0837
Except Sale	$R^2$	.7509	.7515	.7512
Years model	RMSE	.0780	.0778	.0779
Except Sale type	$R^2$	.6970	.6553	.6849
model	RMSE	.0866	.0902	.0877
Except Sale	$R^2$	.6243	.6294	.6259
Variables model	RMSE	.0950	.0969	.0956
Only Artist	$R^2$	.0555	.0609	.0571
Variables model	RMSE	.1518	.1515	.1517
Only Artwork	$R^2$	.5320	.5570	.5394
Variable model	RMSE	.1072	.1035	.1061
Only Sale	$R^2$	.5626	.5602	.5617
Variables model	RMSE	.1038	.1027	.1035

전체 모형의  $R^2$ 는 0.7637로 매우 우수한 예측력을 지니고 있다. 앞서 헤도닉 모형으로 COVID-19의 파급효과를 분석하였다. 인공지능경망으로도 COVID-19의 파급효과를 파악하기 위하여 COVID-19의 전과 후로 모형을 설정하였다. 그 결과 2020-2021의 변수가 제외된 Non COVID-19 모형의  $R^2$ 는 0.7715, 2020-2021의 변수만을 포함하고 있는 COVID-19 모형의  $R^2$ 는 0.7715로 두 모형이 동일한 결과를 보였지만, 전체 모형보다 이 두 모형이 더 우수한 성능을 보였다.

국적과 사망 여부의 작가 요인의 변수를 제외한 모형의 설명력은 0.7329로 기준 모형에 비해 성능은 다소 떨어졌지만 그 차이가 미미하다. 작품 요인의 변수를 제외한 모형의  $R^2$ 는 0.5829로 전체 모형과 비교하였을 때 예측함에 있어서 성능이 우수하지 못한 것을 알 수 있다. 작품적 요인은 크게 작품의 사이즈와 작품의 재료로 구분 지을 수 있다. 이 중 작품의 사이즈 변수를 제외한 모형의 설명력은 0.7196, 작품의 재료 변수를 제외한 모형의 설명력은 0.6495로 작품의 사이즈보다는 작품의 재료가 더 중요한 변수임을 유추해 볼 수 있다. 판매 요인의 변수를 제외한 모형의  $R^2$ 는 0.6259로 기준 모형과 비교하였을 때는 성능이 떨어지는 것으로 나타났다. 판매 요인의 변수에는 세부적으로 경매 회사, 경매가 이루어진 방식의 변수와 판매 연도의 더미 변수가 있다. 따라서 각각의 변수를 누락하며 확인해 본 결과, 경매 회사의 변수를 누락시킨 모형의 설명력은 0.7133, 경매의 방식을 제외한 모형의 설명력은 0.6849, 판매년도의 변수를 제외한 모형에서의 설명력은 0.7512로 전체 변수를 활용한 모형에 비해 성능이 낮아짐을 확인할 수 있다.

다음으로는 작가 요인, 작품 요인, 판매 요인의 각 변수만을 넣은 모형의 성능을 비교하였다. 작가 요인만 있는 모형의 경우  $R^2$ 는 0.0571로 전혀 예측을 하지 못하는 것으로 나타났다. 이를 통해 본 연구에서는 작가 요인보다는 작품 요인과 판매 요인의 변수의 중요도가 더 높은 것으로 볼 수 있을 것이다. 작품 요인만 있는 모형의  $R^2$ 는 0.5394, 판매적 요인만 있는 모형의  $R^2$ 는 0.5617로 두 모형의 성능은 유사한 것으로 나타났지만 판매 요인의 예측력이 조금 더 우수한 것으로 나타났다.

종합해 보자면 본 연구에서는 한국 미술품 데이터 총 14,639개를 활용하여 설정한 30개의 변수를 누락하며 인공지능경망의 결과를 통해 변수의 중요도를 명시적으로 유추해 보고자 하였다. 전체 변수를 넣은 모형에 비해 변수를 누락시킨 모형은 전반적으로 예측력의 측면에서 저조하였으며 각 변수들의 영향이 모두 중요함을 알 수 있었다. 특히 작품 요인의 변수가 가장 중요한 영향을 미치는 것으로 나타났다.

## V. 결과

예상치 못한 COVID-19로 인해 한국 미술계는 전반적으로 얼어붙었다. 그러나 한국의 미술시장은 2021년 상반기 약 1,448억 원의 낙찰총액을 달성하면서 팬데믹 상황의 위기를 빠르게 대처하여 최근 5년 동안의 상반기 통계 중에서 가장 높은 낙찰 총액을 달성하였다. 그 뿐만 아니라 2021년 3월, 고유한 인식 값을 부여한 가상 자산인 NTF(Non-Fungible Token)를 도입한 미술품이 경매 시장에서 낙찰가 약 6억 원에 거래되는 등, 미술품의 투자 수익률을 기대할 수 있는 투자 수단으로서의 역할에 이목이 쏠리고 있다. 이러한 배경에서 본 연구는 미술품 경매시장의 COVID-19의 파급효과를 한국에서 거래된 미술품을 통해 살펴보았다. 또한 전통적인 분석방법인 헤도닉 모형과 최근 화두가 되고 있는 사람의 신경망과 유사한 구조를 지닌 인공지능경망을 이용하여  $R^2$ 와 RMSE를 통해 성능을 비교 분석해 보고자 하였다. 더 나아가 인공지능경망을 통해 한국미술품 가격 형성 요인의 중요도를 추가적으로 분석하였다. 분석을 위해 2015-2021년의 한국에서 거래된 미술품 경매 데이터를 총 14,639건을 수집하였다. 본 연구의 결과는 다음과 같다.

헤도닉 모형으로 분석한 결과, 2015년의 더미 변수를 기준 변수로 2016-2019의 더미 변수는 유의하지 않은 것으로 나타났다. 그러나 COVID-19가 발발한 2020년과 2021년의 변수는 계적으로 유의미한 것으로 나타났다. 2020년에는 2015년보다 미술품 낙찰가가 저조한 것으로 나타났으나 2021년에는 낙찰가가 상승하는 형태를 보였다. 해당 결과는 한국 미술시장의 COVID-19 과급효과를 계량적으로 입증한 것이다. 또한 사망한 작가의 작품가격이 더 높은 “Death Effect”는 존재하지 않은 것으로 나타났으며, 주요 옥션에서 거래가 이루어진 작품의 가격이 더 높은 것으로 확인되었다. 마지막으로 동양의 재료보다는 서양의 재료가 더 가격이 높은 것으로 나타났다.

인공신경망을 활용하여 실증분석하여 헤도닉 모형과 성능을 비교 분석해 본 결과, 인공신경망의  $R^2$ 는 0.7627로 헤도닉 모형의 0.677보다 우수한 것으로 나타났다. 또한 예측 오차를 계산한 결과 인공신경망의 RMSE 0.07576으로 헤도닉 모형의 RMSE인 1.07098와 비교하였을 때, 인공신경망의 성능이 더 우수한 것으로 나타났다. 따라서 전통적인 통계 방법보다 인공신경망이 보다 정확히 예측한다는 것을 보여준다. 이는 선형 함수에 의한 헤도닉 모형에 비해 비선형의 활성화 함수를 사용하는 인공신경망이 미술품 가격을 예측하는데 더 유용할 수 있음을 보여준다. 또한 헤도닉에서는 상호작용 효과가 없기에 수많은 상호작용을 일으키는 인공신경망이 대량, 분산이 높은 미술품 데이터 평가하는 것에 더 유리함을 알 수 있었다.

변수의 중요도를 각 변수를 누락하면서 인공신경망을 반복적으로 실행한 결과, 작품과 판매적 요인이 비슷한 수준으로 중요하고 작가적 요인의 중요도가 상대적으로 떨어지는 것을 확인할 수 있었다.

본 연구에서는 한국 미술품 데이터를 활용하여 COVID-19의 미술시장 과급효과를 분석함에 의의가 있으며, 인공신경망을 활용하여 예측의 성능을 높인 것에 의의가 있다. 그뿐만 아니라 인공신경망이 지닌 “블랙박스”의 단점을 보완하고자 명시적으로 각 변수들의 중요도를 분석함의 시사점이 있다. 이를 통해 산업적 측면에서 대중에게 공개된 데이터를 활용하여 예측력이 높은 가격 모형을 제시할 수 있기에 미술시장에서의 소비자의 정보 비대칭을 해소하여 시장 활성화를 도모할 수 있을 것이다. 학문적인 측면에서는 인공신경망이라

는 알고리즘을 이질적인 미술품 데이터에 적용할 수 있음에 시사점을 지닌다. 그러나 본 연구에서 사용된 데이터는 한국 미술품 데이터 중에서도 공개된 제한된 데이터만을 이용하였기에 향후 표본의 크기가 더 크고, 다양한 미술품 데이터에 대한 실증분석을 필요로 한다. 인공신경망이 미술품 평가에 있어서 빠른 분석이 가능하여 효율적인 측면에서 좋은 도구로써 작용한 것일 뿐, 예술품을 역사적인 맥락, 실제 예술품의 상태, 미학적 의의 등을 종합하여 작품의 가치를 결정하는 미술품 전문가들을 대체할 수 있다는 의미는 아니다. 따라서 본 연구를 통해 더욱 다양한 인공지능 알고리즘들이 미술품이라는 이질적인 데이터에 적절히 응용될 수 있다면 본 연구보다 예측이 잘 되는 효과적인 평가 모형이 개발될 수 있을 것이라 기대한다.

## References

- [1] J. Mei and M. Moses, “Art as an Investment and the underperformance of masterpiece,” *American Economic Review*, Vol. 92, no. 5, pp. 1656-1668, 2002. <https://doi.org/10.2139/ssrn.311701>.
- [2] J. Kang, H. J. Lee, S. H. Jeong, H. S. Lee and K. J. Oh, “Developing a forecasting model for real estate auction prices using artificial intelligence,” *Sustainability*, Vol. 12, no. 7:2899, 2020. <https://doi.org/10.3390/su12072899>.
- [3] V. Limsombunchai, C. Gan and M. Lee, “House price prediction: Hedonic Price Model vs. Artificial Neural Network,” *American Journal of Applied Sciences* Vol. 1, no. 3, pp. 193-201, 2004. <https://doi.org/10.3844/ajassp.2004.193.201>.
- [4] C. M. Kuan and T. Liu, “Forecasting exchange rates using feedforward and recurrent neural networks,” *Journal of Applied Econometrics*, Vol. 10, no. 4, pp. 347 - 364, 1995. <https://doi.org/10.1002/jae.3950100403>.
- [5] G. Grudnitski and L. Osburn, “Forecasting S and P and gold futures prices: An application of neural networks,” *Journal of Futures Markets*, Vol. 13, no. 6, pp. 631 - 643, 1993. <https://doi.org/10.1002/fut.3990130605>.
- [6] D. W. McCann, “A neural network short-term forecast of significant thunderstorms,” *Weather and Forecasting*, Vol. 7, no. 3, pp. 525-534, 1992. [https://doi.org/10.1175/1520-0434\(1992\)007<0525:annstf>2.0.co;2](https://doi.org/10.1175/1520-0434(1992)007<0525:annstf>2.0.co;2).

- [7] C. Marzban, and G. J. Stumpf, “A neural network for tornado prediction based on doppler radar derives attributes,” *Journal of Applied Meteorology*, Vol. 35, no. 5, pp. 617–626, 1996. [https://doi.org/10.1175/1520-0450\(1996\)035<0617:an nftp>2.0.co;2](https://doi.org/10.1175/1520-0450(1996)035<0617:an nftp>2.0.co;2).
- [8] R. Sharda, “Neural networks for the MS/OR analyst: An application bibliography,” *Interfaces*, Vol. 24, no. 2, pp. 116 - 130, 1994. <https://doi.org/10.1287/inte.24.2.116>.
- [9] M. W. Gardner, S. R. Dorling, “Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences,” *Atmospheric Environment*, Vol. 32, no. 14–15, pp. 2627 - 2636, 1998. [https://doi.org/10.1016/s1352-2310\(97\)00447-0](https://doi.org/10.1016/s1352-2310(97)00447-0).
- [10] R. Schalkoff, “Pattern Recognition: Statistical, Structural and Neural Approaches,” Wiley, 1991.
- [11] R. C. Anderson, “Paintings as an investment,” *Economic Inquiry*, Vol. 12, no. 1, pp. 13–26, 1974. <https://doi.org/10.1111/j.1465-7295.1974.tb00223.x>.
- [12] W. J. Baumol, “Unnatural value: or art investment as floating crap game,” *American Economic Review*, Vol. 76, no. 2, pp. 10–14, 1986. <https://doi.org/10.1080/07335113.1985.9942162>.
- [13] J. Pesando, “Art as an investment: the market for modern prints,” *The American Economic Review*, Vol. 83, no. 5, pp. 1075–1089, 1993. <https://www.jstor.org/stable/2117549>.
- [14] M. L. Biey and R. Zanola, “Investment in Paintings: A Short-Run Price Index,” *Journal of Cultural Economics*, Vol. 23, no. 3, pp. 211 - 222, 1999. <https://www.jstor.org/stable/41810697>.
- [15] W. N. Goetzmann, “Accounting for taste: Art and the financial markets over three centuries,” *The American Economic Review*, Vol. 83, no. 5, pp. 1370–1376, 1993. <https://www.jstor.org/stable/2117568>.
- [16] O. Chanel, L. A. Gerard-Varet and V. Ginsburgh, “Prices and returns on paintings: an exercise on how to price the priceless,” *The Geneva Papers on Risk and Insurance Theory*, Vol. 19, no. 1, pp. 7–21, 1994. <https://doi.org/10.1007/bf01112011>.
- [17] O. Chanel, “Is art market behaviour predictable?,” *European Economic Review*, Vol. 39, no. 3–4, pp. 519–527, 1995. [https://doi.org/10.1016/0014-2921\(94\)00058-8](https://doi.org/10.1016/0014-2921(94)00058-8).
- [18] O. Chanel, L. A. Gerard-Varet and V. Ginsburgh, “The relevance of Hedonic Price Indices: The case of paintings,” *Journal of Cultural Economics*, Vol. 20, no. 1, pp. 1–24, 1996. <https://doi.org/10.1007/s10824-005-1024-3>.
- [19] H.A.C.K. Hettiarachchi and B.M.S.G. Banneheka, “Time series regression and artificial neural network approaches for forecasting unit price of tea at Colombo auction,” *Journal of the National Science Foundation of Sri Lanka*, Vol. 41, no. 1, pp. 35–40, 2013 <https://doi.org/10.4038/jnsfsv41i1.5331>.
- [20] I. M. Nasser, M. Al-Shawwa, S. S. Abu-Naser, “Developing Artificial Neural Network for predicting mobile phone price range,” *International Journal of Academic Information Systems Research*, Vol. 3, no. 2, pp. 1–6, 2019. <http://dstore.alazhar.edu.ps/xmlui/handle/123456789/45>.
- [21] H. Mombeini and A. Yazdani-Chamzini, “Modeling gold price via Artificial Neural Network,” *Journal of Economics, Business and Management*, Vol. 3, no. 7, pp.699–703, 2015. <https://doi.org/10.7763/joebm.2015.v3.269>.
- [22] O. Ashenfelter and K. Graddy, “Auctions and the price of art,” *Journal of Economics Literature*, Vol. 41, no. 3, pp. 763–787, 2003. <https://doi.org/10.1257/jel.41.3.763>.
- [23] K. J. Lancaster, “A new approach to consumer theory,” *Journal of Political Economy*, Vol. 74, no. 2, pp. 132 - 157, 1966. <https://doi.org/10.1086/259131>.
- [24] Soonim Kim, Youngdae Lee, “A Survey Research on the Auction and Art Price Index,” *The Journal of the Convergence on Culture Technology(JCCT)*, Vol. 1, no 2, pp. 37–44, 2015. <https://doi.org/10.17703/JCCT.2015.1.2.37>.
- [25] R. B. Ekelund, Jr, R. W. Ressler and J. K. Watson, “The “Death-Effect” in Art prices: A Demand-side Exploration,” *Journal of Cultural Economics*, Vol. 24, no. 4, pp. 283–300, 2000. <http://doi.org/10.1023/A:1007618221648>.
- [26] Ji In, Lee, Jeong Seok Song, “A Research on Prediction of the Art Price using Multivariate Long Short Term Memory Recurrent Neural Network Deep Learning Model,” *The Journal of the Korea Contents Association*, Vol. 21, no. 6, pp. 552–560, 2021. <http://doi.org/10.5392/JKCA.2021.06.552>.