

# Art Price Prediction Using Decision Tree-Based Machine Learning Methods\*

## 결정 트리 기반 학습 모형을 이용한 미술품 경매 가격 예측

Dongryul Jang(First Author)

Department of Culture and Arts Management,  
Graduate School, Hongik University  
([dongryulj@naver.com](mailto:dongryulj@naver.com))

Minjae Park(Corresponding Author)

College of Business Administration, Hongik University  
([mjpark@hongik.ac.kr](mailto:mjpark@hongik.ac.kr))

.....

Recently, many researchers not only from industry but also from academia have interested in the art finance market. Although many people have studied growing art finance market, very few studies on the prediction model to evaluate the art price have been conducted. Therefore, in this study we have gathered a database of 12,105 paintings auctioned between 2009 and 2018 and have implemented decision tree-based machine learning algorithms (e.g., random forests, gradient boosting, XGboost) to develop prediction models for art prices and to improve the reliability for art experts' estimates accurately. We have compared the prediction accuracy of the proposed approach based on root mean square error and mean absolute error. As a result of the analysis, we noticed that experts' estimates from auction houses are more accurate only for high-priced artworks but overestimates low-priced artworks. On the other hand, the suggested prediction model's accuracy considering decision tree-based model is better than the accuracy based on the parametric OLS model. Finally, we test the accuracy of prediction models considering expert evaluation to enhance the models' predictive power. These results show that an integrated approach between expert appraisal systems and statistical models improves the prediction accuracy for artworks' price.

Key Words: art price, decision tree, extreme gradient boosting, gradient boosting, random forests

.....

Submission Date: 07. 28. 2020

Revised Date: (1st: 11. 15. 2020)

Accepted Date: 12. 09. 2020

\* Minjae Park's work was supported by the National Research Foundation of Korea(NRF) grant funded by the Korea government(MSIT) (NRF-2020R1F1A104823711).

A previous version of this paper won a third prize at the "18th Thesis Competition" hosted by Statistics Korea.

Copyright 2011 THE KOREAN ACADEMIC SOCIETY OF BUSINESS ADMINISTRATION

This is an open access article distributed under the terms of the Creative Commons Attribution License 4.0, which permits unrestricted, distribution, and reproduction in any medium, provided the original work is properly cited.

## 1. 서론

2018년 문화체육관광부는 ‘미술로 행복한 삶’이라는 비전과 함께 ‘미술진흥 중장기 계획(2018~2022)’을 발표하였다(Ministry of Culture, Sports and Tourism, 2018). 정책 목표 중 하나는 투명하고 공정한 시장을 확립하여 선순환하는 시장 생태계를 조성하는 것이다. 여기서 공정한 미술 시장은 미술품 평가 체계와 깊게 맞닿아 있다. 미술계는 화랑 중심의 공급 시장이 가져온 이중 가격제와 불투명한 거래 정보로 인한 구조적인 불합리함을 가지고 있기 때문이다(Kim et al., 2016). 이러한 문제를 해결하기 위해서는 투명하고 신뢰성 있는 미술품 평가가 이루어져야 한다. 창작물인 미술품에 대한 평가는 그동안 감정(appraisal)에 의존해왔으나 인간에 의한 감정 평가는 가격의 적정성을 판단하기 어렵다. 미술계에서는 감정 정보의 부족과 감정사 교육 시스템 부재, 이해 충돌과 관련한 감정사의 윤리성 문제 등 감정 평가의 공정성과 신뢰성과 관련한 문제가 계속 언급되고 있으며(Lee, 2019), 관련 연구들은 경매 시장에서 감정 추정가가 실제로 편향될 수 있음을 지적해왔다.

최근 재화의 가격 예측을 위해 기계 학습(machine learning)이 활발히 이용되고 있다. 부동산(Lee and Park, 2016; Park and Bae, 2015), 주식(Choudhry and Garg, 2008; Patel et al., 2015; Shen, Jiang, and Zhang, 2012), 에너지(Yu, Dai, and Tang, 2016) 분야에서는 재화의 가격 및 수요를 예측하기 위해 기계 학습을 이용하였으며, 이들 연구에서 고안된 비모수 모형은 헤도닉 가격 모형과 같은 모수 모형에 비해 높은 예측 성능을 보였다. 미술계에서는 경매 회사인 소더비(sotheby's)가 감정 과정의 효율성과 정확성을 높이기 위해 자동화

평가 기법으로서 기계 학습을 이용하고 있다(Bailey, 2020), Ayub, Orban and Mukund(2017)와 Aubry et al.(2019)는 CNN(convolutional neural network)을 이용하여 이미지 변수를 반영한 가격 예측 모형의 성능을 분석하였으며, Jang and Park(2020a)은 경매 데이터를 토대로 미술품 가격에 대한 기계학습 모형의 예측 오차가 모수 모형보다 낮음을 보여주었다. 그럼에도 미술품 가격에 관한 연구는 가격결정요인(Higgs and Worthington, 2005; Nahm, 2011; Park and Shin, 2012; Jang and Park, 2020b) 및 경제적 가치(Garay, 2021; Taylor and Coleman, 2011; Mei and Moses, 2005a) 규명에 집중되어 왔으며 변수 개발의 어려움과 활용 가능한 데이터의 부족으로 인해 미술품 가격 예측 모형의 개발은 제한적으로 이루어지고 있는 실정이다.

이러한 배경에서 본 연구는 결정 트리(decision tree)를 기반으로 한 미술품 가격 예측 모형을 제안한다. 결정 트리를 활용하는 이유는 첫째로 결정 트리는 다른 기계 학습 알고리즘에 비해 쉽게 이해할 수 있기 때문이다. 장기적으로 볼 때, 현실에서 감정 평가와 예측 모형이 유기적으로 운용되기 위해서는 실무자들이 모형을 쉽게 이해할 수 있어야 한다. 결정 트리는 인공신경망(artificial neural networks)이나 서포트 벡터 머신(support vector machine) 같은 블랙 박스 알고리즘보다 직관적이고 명료하기 때문에 이론적 진입장벽이 낮다는 장점이 있다. 두번째로 결정 트리에 기반한 알고리즘들은 여러 대회에서 우수한 성능을 인정받았을 뿐 아니라 다양한 기법과의 결합을 통해 확장 가능성이 높기 때문이다. 마지막으로 기존 연구(Aubry et al., 2019; Ayub, Orban, and Mukund, 2017)들이 이미지 변수를 반영하기 위해 딥러닝(deep learning)을 조명해온 것과 달리, 결정 트리의 예측력을 감정 평가와 면밀

히 비교 분석한 사례는 우리가 아는 한 거의 없었기 때문이다. 공개적으로 신뢰할 수 있는 가격의 부재가 미술품 구매 결정의 큰 걸림돌이 되는만큼(Artsy, 2019), 예측력이 우수한 가격 모형을 개발할 수 있다면 작품의 가격 투명성을 개선하고 잠재 구매자의 합리적인 의사결정을 지원함으로써 시장의 유동성을 높일 수 있을 것이다.

본 연구를 위해 2009년부터 2018년 동안 케이옥션과 서울 옥션에서 거래된 경매 작품들 중, 경매사의 예상 판매 추정가(이하 '감정 추정가'라고 함)와 세부 작품 정보가 포함된 12,105건의 오프라인, 온라인 경매 데이터를 수집하였다. 본 연구에서 사용된 결정 트리 기반 알고리즘은 배깅(bagging) 기반의 랜덤 포레스트(random forests)와 부스팅(boosting) 계열의 그래디언트 부스팅(gradient boosting), XG부스트(eXtreme gradient boosting)이며, 선형 회귀와 k-최근접 이웃(k-nearest neighbor) 모형을 추가로 구축하여 모형 간 성능을 비교하였다. 분석은 공개된 세부 작품 정보를 변수로 하는 가격 예측 모형을 구축한 후, 실제 감정 가격과의 예측력 차이를 비교하는 방식으로 이루어졌다. 이후 감정 추정가를 변수로 투입한 예측 모형을 추가적으로 구축하여 모형의 성능 개선 정도를 측정하였다. 모형의 예측력은 평균 제곱근 오차(RMSE, root mean square error)와 평균 절대 오차(MAE, mean absolute error)를 기준으로 평가하였으며 계산된 예측 값을 토대로 커널 밀도 곡선을 추정하여 각 모형의 편향성을 분석하였다.

본 논문의 구성은 다음과 같다. 2장에서는 미술품 가격 모형의 필요성과 개발 가능성, 활용 모형과 관련한 이론적 배경에 대해 설명한다. 3장에서는 본 분석을 위해 사용된 데이터와 변수에 대해 정의한다. 4장에서는 모형을 미세 조정하고 평가 결과를 토대

로 미술품 평가 기법으로서 기계 학습의 이용 가능성을 논한다. 끝으로 5장을 결론으로 본 논문을 마무리한다.

## II. 이론적 배경

### 2.1 미술품 가격 평가 모형의 필요성

미술품은 특성이 이질적이고 효용 가치가 개인마다 다르므로 적정 가격을 판단하기 어렵다. 따라서 미술계에 폭넓은 지식을 가진 전문가의 평가 가치는 미술품 가격의 토대가 된다. 이처럼 사실에 기초하여 소유물의 가치를 평가하고 의견을 제시하는 것을 시가 감정(이하 '감정'이라고 함)이라고 한다. 다만 감정 평가에는 여러 한계가 존재한다.

첫 번째는 국내 감정 현실에 관한 문제다. 일반적으로 평론가, 화랑, 교수 등 오랜 교육을 받고 미술계에서 활동해온 전문가들이 감정인으로 종사한다. 국내에는 이들의 자격과 역량을 검토 및 감독하기 위해 여러 감정 기관이 존재한다. 다만 감정 정보의 미비, 전문 교육 시스템의 부족, 이해충돌과 관련한 감정사의 윤리적 문제 등 감정의 신뢰성과 공정성에 관한 여러 문제들이 시장 관계자를 중심으로 계속해서 지적되고 있다(Lee, 2019). 이러한 문제를 해결하기 위해 행정 차원에서는 표준 감정서 도입, 감정인의 자격 제도 검토, 정부 미술은행의 감정 업무 수행 등 감정의 제도화 방안을 검토하고 있으나(Ministry of Culture, Sports and Tourism, 2018), 아직 논의 단계에 머무를 뿐 실질적인 성과로 이어지지 못하고 있다.

두 번째는 경매사 추정가의 편향 위험이다. 경매

시장은 미술 시장에서 가장 빠르게 성장하고 있는 시장이다. 가격 비공개를 원칙으로 하는 화랑 시장과 달리, 경매사는 자체적으로 감정 추정가를 산정하고 공개하여 시장 내 정보 비대칭을 해소하고 있다. 다만 경매사 추정가는 편향될 위험이 있다(Bauwens and Ginsburgh, 2000; Beggs and Graddy, 1997; Mei and Moses, 2005b). 추정 편향의 원인은 첫째로 경매사가 추정 가격 범위의 최저가는 높고 최고가는 낮춤으로써 구매력이 낮은 입찰자보다 높은 입찰자의 구매 가능성을 높이고(Bauwens and Ginsburgh, 2000), 둘째로는 판매 수수료 수익을 높이기 위해 의도적으로 추정가를 높게 잡으려 한다는 것이다(Mei and Moses, 2005b). Ashenfelter, Graddy and Stevens(2002)에 따르면 판매자가 받아들일 수 있는 최저 가격인 유보 가격(reserve price)은 경매사 감정 하한가의 70~80% 수준이다. 소더비의 판매 조건에서는 유보 가격이 추정 하한가를 초과할 수 없다고 규정하며 유보 가격은 일반적으로 하한가의 50~100% 범위 수준에 있다(McAndrew and Thompson 2007). 이러한 이유들로 인해 경매사의 감정 추정가는 실제 판매될 가격보다 과대평가될 위험이 존재한다. 물론 현실에는 수많은 경매사가 존재하고 경매사는 순수히 판매를 목적으로 추정가를 공개하므로 엄밀한 의미에서 경매사 추정가를 진실된 감정 가격이라고 전제하기는 어렵다. 다만 감정 평가액이 구매자 지불 가격의 기준이 되는 만큼(Beggs and Graddy, 2009), 가장 빠르게 성장하고 있는 경매 시장에서 공개된 추정가에 편향이 존재한다면 구매자의 합리적인 판단은 어려워진다.

세번째는 평가의 효율성에 관한 문제다. 최근 온라인 미술 시장은 기존 오프라인 시장의 높은 진입장벽을 해소함으로써 신규 콜렉터를 빠르게 늘리고 있다

(McAndrew, 2019). 크리스티와 소더비를 비롯한 상급 경매 회사들 뿐 아니라 국내 경매 시장 또한 전체 경매 횟수 중에서 온라인 경매가 92%를 차지하여 온라인 환경에서 미술품 거래량은 빠르게 증가하고 있다(Korea Arts Management Service, 2019). 늘어나는 미술품 수요는 평가 대상의 양적 증가로 이어진다. 문제는 인간의 개입을 필요로 하는 감정 평가가 양적인 측면에서 한계를 가진다는 점이다. 따라서 늘어나는 수요와 공급을 상쇄하기 위해서는 전문가 평가 과정의 효율성을 높이는 방안이 필요하다. 일례로 소더비는 감정사의 반복 작업을 최소화하는 등, 평가의 효율과 정확성을 높이기 위해 기계 학습에 기반한 자동화 평가 기법을 주목하고 있다(Bailey, 2020). 이외에도 가격 모형은 산정된 가격의 적정성을 확보하기 위한 전문가의 시장 분석 도구로서 고려될 수 있다. 이처럼 자동화 평가의 이점은 단순히 모형이 산출하는 가격을 그대로 공시하는 것에 국한되지 않는다. 감정인의 평가 가치의 객관성을 부여하고 평가의 효율을 높인다는 점에서 자동화 평가 기법에 대한 연구는 앞으로 중요해질 것이다.

살펴본 바와 같이 감정 평가는 시장에서의 중요성과 함께 그에 준하는 신뢰성과 효율성 개선이 요구되는 상황이다. 잠재 구매자의 미술품 구매를 방해하는 요인 중 하나는 공개된 가격 정보의 낮은 신뢰성이다(Artsy, 2019). 일반적으로 재화의 가격 투명성 증대가 시장의 유동성 증가로 이어지는만큼, 만일 모두에게 공개된 데이터를 토대로 구축한 가격 예측 모형이 추정 편향에 강건하고 예측력 또한 우수하다면, 미술 시장의 가격 투명성을 개선함으로써 시장의 유동성을 높일 수 있을 것이다.

## 2.2 미술품 가격 평가 모형 연구

미술품을 투자 상품으로 주목함에 따라 미술품에 관한 연구는 수익률(Garay, 2019; Mei and Moses, 2005a; Taylor and Coleman, 2011)과 가격결정요인(Higgs and Worthington, 2005; Nahm, 2011; Jang and Park, 2020b; Park and Shin, 2012) 분석에 초점을 맞춰왔다. 반면 미술품이 가지는 질적 특성과 활용 가능한 데이터의 부족으로 인해 가격 예측 모형에 관한 연구는 매우 제한적으로 이루어졌다. 그중 Sproule and Valsan(2006)은 경매 데이터를 토대로 헤도닉 회귀 모형을 구축하여 모형의 예측치와 경매사 감정가를 비교 분석하였다. 이들은 낙찰가에 대한 회귀 모형의 설명력이 감정 추정가에 미치지 못한 점을 들어 미술품 가격에 대한 전문가 평가의 중요성을 강조하였다. 마찬가지로 Taylor and Coleman(2011)은 헤도닉 회귀 모형보다 우수한 경매사 감정가의 예측력을 보고하였다. Fedderke and Li(2020)는 아프리카 미술품 경매 데이터에 포함된 작가 40명에 대한 회귀 모형을 각각 구축하여 예측 정확도를 평가하였다. 이들은 오차 측면에서 회귀 모형의 예측력이 경매사 감정가에 준한다고 보았지만, 개별 모형마다 예측력의 편차가 크고 예측 데이터의 크기가 작기에 보다 많은 데이터를 활용한 정밀한 모형 평가가 요구된다. 앞에 소개한 연구(Sproule and Valsan, 2006; Taylor and Coleman, 2011; Fedderke and Li, 2020)는 최소제곱법(ordinary least squares)에 기반을 두는 선형 회귀(이하 'OLS'라고 함)를 이용하여 모형을 구축하였다. 다만 모수적 방법인 OLS는 경직된 함수 형태를 가지고 데이터 형태에 관한 엄격한 가정을 요구하므로 명시된 함수 형태가 실제와 다르다면 예측 정확도가 감소하는 단점이 있다(James,

Witten, Hastie, and Tibshirani, 2013).

빅데이터 분야에서 고안된 기계 학습은 모수적 방법이 요구하는 가정에 구애받지 않으며 비선형성과 다중공선성이 존재하는 데이터에서도 우수한 예측 성능을 기대할 수 있다. 최근 연구들은 불확실한 미술품 가격을 정량적으로 평가하기 위해 기계 학습을 이용하였다. Aubry et al.(2019)과 Ayub, Orban and Mukund(2017)은 미술품의 이미지 변수를 반영한 딥 러닝 모형을 구축하였다. 이들 연구에 따르면 이미지 변수는 모형의 예측력을 제한적으로 개선한다. 대신 Aubry et al.(2019)은  $R^2$  측면에서 신경망 모델이 OLS 보다 예측력이 우수하며 감정 평가에 예측 추정치를 반영함으로써 평가의 정확도를 높일 수 있음을 보여주었다. 또한 그들은 저가 작품에는 경매사의 추정 오류가 반영될 수 있으므로 기계 학습의 예측치는 이러한 오류를 극복할 수 있다는 것을 강조하였다. Jang and Park(2020a)는 과거 판매 기록으로 측정된 작가별 명성을 기계 학습 모형에 반영하여 기계 학습의 예측 오차가 OLS 보다 25~40%가량 낮음을 국내 경매 데이터를 토대로 입증하였다. 이 연구는 미술품 가격을 평가하는 데 있어 기계 학습 기법의 응용 가능성을 국내에서 처음으로 입증한 사례다. 다만 이들의 연구는 모형 간 예측력 비교 분석에 국한되어 감정 추정가를 분석에서 제외했다는 한계를 가진다.

## 2.3 평가 모형

### 2.3.1 결정 트리 기반 알고리즘

결정 트리(decision tree)의 핵심적인 아이디어는 하나의 값을 구하기 위해 주어진 변수들의 차원 공간을 다수의 영역으로 균질하게 분할하는 것이다.



회귀 트리에서 데이터를 균질하게 분할한다는 것은 설명 변수를 기준으로 잔차제곱합(RSS, residual sum of squares)을 가장 작게 만드는 부분 집합( $R_1, \dots, R_j$ )으로 데이터를 계속해서 분할해 간다는 것을 의미하며, 트리 모형의 목적은 아래 식으로 주어진 RSS를 가장 작게 만드는 부분 집합을 찾는 것이다(James, Witten, Hastie, and Tibshirani, 2013).

$$\sum_{j=1}^J \sum_{i \in R_j} (y_i - \hat{y}_{R_j})^2 \quad (1)$$

$\hat{y}_{R_j}$ 는  $j$ 번째 부분 집합 안에 존재하는 훈련 관측치들의 평균값이다. 결정 트리는 OLS와 같은 모수적 방법과 달리 주어진 데이터로부터 점진적으로 학습해가므로 다중공선성이나 변수 간의 상호작용 효과로부터 강건하다(Grömping, 2009). 또한 나무 구조형태를 이용하는 결정 트리는 다른 방법에 비해 사용자가 그 과정을 쉽게 이해할 수 있고 변수 간의 상호작용 효과를 해석하기 용이하기 때문에 많이 이용된다(Huh and Jung, 2013). 본 연구에서는 대표적인 결정 트리 기반 알고리즘인 랜덤 포레스트, 그래디언트 부스팅, XG부스트를 이용하여 작품 가격을 추정한다.

#### (1) 랜덤 포레스트

단일 회귀 트리는 완성된 모형에 새로운 값을 투입할 때 예측치의 변동이 크다. 이러한 높은 분산을 해소하기 위해 여러 개의 회귀 트리를 결합하는 배깅이 고안되었다(Breiman, 1996). 배깅의 핵심 아이디어는 부트스트랩 표본 추출된 복수의 데이터 셋마다 모형을 학습시키고 모형 결과치들을 결합하여 기저 모형의 분산을 감소시키는 것이다. 배깅은 수식 (2)

와 같이 표현된다(James, Witten, Hastie, and Tibshirani, 2013).

$$\hat{f}_{\text{bagging}}(x) = \frac{1}{B} \sum_{b=1}^B \hat{f}^{*b}(x) \quad (2)$$

$B$ 는 부트스트랩을 통해 생성된 데이터 셋의 개수이며  $\hat{f}^{*b}(x)$ 는  $b$ 번째 데이터 셋에서 학습된 회귀 트리의 결과값이다.

랜덤 포레스트(Breiman, 2001)는 배깅을 이용한 앙상블 모형으로 변수 추출 방식에서 배깅과 차이를 가진다. 배깅은 사용 가능한 모든 변수를 사용하여 각각의 트리 모형을 구축하는 반면, 랜덤 포레스트는 전체 변수 중에서 일부 변수만을 무작위로 선정하여 트리의 분할 기준으로 사용한다. 따라서 투입되는 변수의 크기가 랜덤 포레스트의 주요한 초매개변수(hyper parameter)가 된다. 이같이 랜덤 포레스트는 데이터 셋마다 분할 기준을 달리하여 트리의 상관성을 줄이고 모형 훈련의 다양성을 높인다. 이 과정은 단순 배깅의 경우보다 분산을 감소시킨다.

랜덤 포레스트는 부트스트랩 표본 추출되지 않은 전체 중의 1/3 가량의 데이터를 out-of-bag 데이터로 활용하여 변수 중요도를 정량화할 수 있다. 이 오차를 OOB error라고 하며 수식 (3)으로 나타낸다.

$$OOB \text{ error} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3)$$

$y_i$ 는  $n$ 개 데이터 중  $i$ 번째 관측치의 결과 변수 값이며  $\hat{y}_i$ 는 OOB 데이터로 산출된 예측 값이다. 이때 변수 값을 무작위로 치환하여 새로 OOB error를 구한 후, 정상 오차와 치환된 오차의 차이를 계산함으로써 변수의 상대적인 중요도를 구할 수 있다.

변수 값을 무작위로 치환한다는 의미는 예측 변수와 결과 변수 간의 상관관계를 제거한다는 의미다.  $j$  번째 변수의 중요도  $V_j$ 는 수식 (4)로 표현된다.

$$V_j = \frac{1}{B} \sum_{b=1}^B (\overline{OOB\ error} - OOB\ error) \quad (4)$$

$B$ 는 성장시킴 트리의 개수를 의미하며  $\overline{OOB\ error}$ 는 무작위 치환된 변수를 활용하여 추정된 예측 오차다. 변수 중요도는 두 개의 OOB error의 차이를 평균한 값으로 정의된다.

(2) 그래디언트 부스팅

부스팅은 다음의 관점에서 배경과 다르다. 첫째로 부스팅은 부트스트랩을 이용하여 독립적인 복수의 트리를 만들지 않는다. 대신 최초 트리 모형의 잔차를 줄여나가는 방식으로 학습 모형을 수정해나간다. 즉,  $m$ 번째 트리 모형의 목적은 기존의  $y$ 값이 아닌  $m - 1$ 번째 트리의 잔차를 정확히 예측하는 것이다. 두 번째 차이점은 트리 노드를 더 이상 분할되지 않을 때까지 성장시키는 배경과 랜덤 포레스트와 달리, 부스팅은 트리의 분할 기준을 강력하게 통제하여 하나의 약한(weak) 학습기로서 트리를 얇게 성장시킨다는 점이다. 그래디언트 부스팅(Friedman, 2001)은 기울기 하강법을 이용한 트리 앙상블 기법으로 모형의 구축 과정을 단계적으로 설명하면 다음과 같다(James, Witten, Hastie, and Tibshirani, 2013).

- a. 훈련 데이터  $i$ 에 대한 잔차  $r_i$ 를  $y_i$ 로 설정한다.
- b.  $m(1, 2, \dots, M)$ 에 대하여 다음 과정을 반복한다.
  - i)  $d$ 개의 분할 깊이를 가지는 트리 함수  $\hat{f}^m(x)$ 를 구축하여 잔차  $r_i$ 를 예측한다.

- ii) i)에서 구해진 새로운 트리 함수에 가중치  $(\lambda)$ 를 부여하여  $\hat{f}$ 를 업데이트 한다.

$$\hat{f}(x) \leftarrow \hat{f}(x) + \lambda \hat{f}^m(x) \quad (5)$$

- iii) 잔차를 업데이트 한다.

$$r_i \leftarrow r_i - \lambda \hat{f}^m(x_i) \quad (6)$$

- c. 부스팅 모형을 출력한다.

$$\hat{f}_{\text{boosting}}(x) = \sum_{m=1}^M \lambda \hat{f}^m(x) \quad (7)$$

부스팅은 랜덤 포레스트에 비해 보다 정밀한 초매개변수 조율을 요구한다. 주요 매개변수는 잔차의 반복 추정 횟수  $m$ 과 트리의 노드 깊이  $d$ , 잔차의 개선 정도를 제어하는  $\lambda(0 < \lambda < 1)$ 이다. 특히  $\lambda$ 의 경우 0에 가까워질수록 정밀한 모형 훈련이 가능하지만 최적화를 위해 높은  $m$ 값을 요구하며  $m$ 값이 높아질수록 연산 시간은 기하급수적으로 증가한다.

(3) XG부스트

Chen and Guestrin(2016)이 고안한 XG부스트(XGboost, extreme gradient boost)는 높은 예측력과 빠른 속도로 최근에 가장 주목받는 기계 학습 알고리즘이다. 그래디언트 부스팅에 기반한 XG부스트는 전과 동일하게 분류회귀트리(CART, classification and regression trees)를 사용한 얇은 트리 모형을 계속 구축해 나가며 트리 성장후에 별도의 가지치기를 요구하지 않는다. 다만 XGBoost는 GBM에는 없는 정규화 항을 모형에 도입하여 과적합을 최소화하며 병렬 처리를 통해 빠른 계산이 가능하다는 장점이 있다.

### 2.3.2 k-최근접 이웃

k-최근접 이웃의 기본적인 아이디어는 유사한 값들은 서로 가까이에 위치한다는 것이다. 따라서 유사도는 두 데이터 간의 거리로 측정된다. k-최근접 이웃은 변수를 축으로 하여 데이터를 매핑(mapping)했을 때 투입된 값에서 가장 가까이에 위치한 k개의 값을 이용하여 예측 및 분류 문제를 해결한다. 회귀 문제에서는 수식 (8)과 같이 근접한 k개 값의 평균을 결과값으로 산출한다.

$$\hat{f}_{kNN}(x) = \frac{1}{k} \sum_i^k y_i \quad (8)$$

$y_i$ 는 투입된 예측 값에 가장 가까이에 위치한  $i$ 번째 데이터의 결과값이다.  $k$ 는 예측 값에 근접한 데이터의 개수다.  $k$ 는 k-최근접 이웃의 주요한 초 매개변수로 지나치게 클 경우 결과 값들을 결정하는 지역적 구조에 의한 유의미한 차이마저 상쇄되어 과소적합이 발생한다. 반대로  $k$ 가 지나치게 작을 경우 예측 값은 가장 가까이에 위치한 단 몇 개의 데이터에 의존하므로 과대적합을 야기한다.

## III. 연구 방법 및 분석 자료

### 3.1 연구 방법

모형 구축에는 오프라인 경매 데이터(2009-2017)와 온라인 경매 데이터(2014-2017) 9,570개가 사용되었다. 모형의 적정 초 매개변수는 모형 별 격자 탐색(grid search)으로 결정하였다. 격자 탐색은 최

적의 초 매개변수를 찾기 위해 사용자가 지정한 범위 내 모든 초 매개변수 조합의 예측력을 평가한다. 본 연구는 별도의 검증 데이터 대신 훈련 데이터에 대한 5겹 교차검증으로 격자 탐색을 수행하여 예측 데이터(2018년 데이터)가 모형 훈련 과정에 관여하지 않도록 하였다. 이후 최종 구축된 모형을 이용하여 2018년 낙찰된 2,535개의 미술품 가격을 예측하고 모형별 성능을 평가하였다. 예측력 평가 지표는 평균 제곱근오차(RMSE, root mean squared error)와 평균절대오차(MAE, mean absolute error)이다. 예측 오차 외에 예측치의 분포 형태를 파악하기 위해 모형 별로 결과값에 대한 커널 밀도 곡선을 추정하였다. 이 과정이 끝난 후, 감정 추정가를 투입 변수로 활용하여 동일한 방법으로 모형을 구축하였다. 해당 과정을 통해 전문가의 감정 평가가 모형에 반영될 때의 성능 변화를 확인한다.

### 3.2 데이터

분석을 위해 서울 옥션과 케이 옥션에서 공개한 정기 경매 데이터 중에서 최종 낙찰까지 이루어진 오프라인, 온라인 경매 데이터 총 12,105건을 수집하였다. 작품 데이터는 최종 낙찰가와 감정 추정가, 작품 특성에 관한 정보를 포함한다. 수집된 데이터의 판매 유형별 기술 통계량을 다음 <Table 1>로 제시한다. 전체 12,105건의 낙찰품 중에서 온라인 경매 작품이 오프라인에 비해 약 40%가량 많은 반면 총액은 오프라인 경매가 온라인 경매에 비해 13.5배, 평균 낙찰가는 19배가량 높은 것으로 나타났다. 온라인 경매의 표본 기간이 오프라인에 비해 5년 짧은 점을 감안할 때, 수집된 데이터 내에서 온라인 경매는 높은 거래량과 낮은 가격 수준을 가지는 것을 알 수 있다.



〈Table 1〉 수집된 표본의 기술 통계량

|       | 전체              | 온라인 경매(2014~2018) | 오프라인 경매(2009~2018) |
|-------|-----------------|-------------------|--------------------|
| 개수    |                 |                   |                    |
| 낙찰품   | 12,105          | 7,069             | 5,036              |
| 금액(₩) |                 |                   |                    |
| 총액    | 306,095,310,000 | 21,113,110,000    | 284,982,200,000    |
| 평균가   | 25,286,684      | 2,986,718         | 56,588,999         |
| 최고가   | 4,700,000,000   | 450,000,000       | 4,700,000,000      |
| 최저가   | 70,000          | 70,000            | 300,000            |
| 표준 편차 | 106,006,510     | 10,403,421        | 158,686,539        |

### 3.3 변수

본 연구는 예측력을 높이기 위해 공개된 경매 데이터 중에서 활용 가능한 모든 변수를 모형에 포함하였다. 사용된 변수를 요약하여 〈Table 2〉로 제시한다.

모형의 결과 변수는 경매 낙찰가에 자연 로그를 취한 값이다. 경매사는 추정가를 범위의 형태로 제시하므로 본 분석에서는 감정 추정가를 '(최저 추정가 + 최고 추정가)/2'로 정의하였다.

변수는 작품 특성 변수, 작가 특성 변수, 시장 특성 변수 세 가지로 구분할 수 있다(Worthington and Higgs, 2006). 작가 특성 변수는 작가 개인의 정체성을 통제하는 변수로 본 분석에서는 작가의 출생 및 사망 연도, 작가 사망 여부, 작가의 나이 및 교육 수준(출신 학교, 유학 여부)처럼 작가 신상에 관한 정보를 포함한다. 작가의 명성은 작품 가격을 결정하는 중요한 요인이다. Anderson(1974)과 Taylor and Coleman(2011)는 작가의 이전 판매 가격을 평균한 값을 명성 변수로 활용함으로써 모형의 적합도를 개선하였다. 마찬가지로 Fedderke and Li (2020)는 작가의 정체성을 통제하기 위해 거래 작품 수를 더미화 하여 변수로 활용하였다. 이와 동일하게

본 연구는 확보된 데이터 내에서 이전 기간(2009년 ~2017년) 동안 작가 별 판매 작품 횟수와 평균 가격을 계산하여 모형에 투입하였다. 평균 가격의 경우 편차를 줄이기 위해 자연 로그를 취하였다. 작품 특성 요인은 크기와 소재처럼 작품의 물리적 특성을 반영한다. 일반적으로 같은 작가의 작품이라면 크기가 클수록 가격이 상승한다. 국내 미술시장에서는 작품의 호수와 작가 별 호당 가격을 곱하여 가격을 책정하는 호당가격제가 통용된다. 따라서 작품의 크기는 필히 변수로 반영되어야 하며 본 연구에서는 크기 변화가 불균등한 호당 크기 대신 작품의 높이, 너비의 센티미터(cm)로 작품의 크기를 통제하였다. 여러 판본을 가지는 판화는 작품 특성이 회화와 상이하므로 판화와 회화를 범주 변수로 구분하였다. 바탕 재료는 작품이 그려진 소재로 캔버스, 종이, 한지, 섬유(리넨, 비단 등), 기타 재료로 구분하였다. 사용 재료는 작품의 주재료로 유채, 아크릴, 채색, 수묵, 잉크, 파슈, 안료, 혼합재료, 기타로 구분하였다. 각 재료는 완전히 독립적이지 않으며 한 작품이 두 가지 이상의 재료를 사용하는 것을 허용하였다. 〈Table 1〉에서 살펴본 바와 같이, 경매 유형에 따라 작품의 가격대는 상이하다. 경매 유형 별 구매자의 특성과 가

〈Table 2〉 변수 목록

| 변수       | 정의   | 자료 유형 |
|----------|--|-------|
| 결과 변수    |  |       |
| 낙찰가      | $\ln(\text{낙찰 가격})$                              | 연속형   |
| 감정 추정가   |  |       |
| "        | $\ln((\text{최저 추정가} + \text{최고 추정가})/2)$         | 연속형   |
| 투입 변수    |  |       |
| 출생 연도    | 작가의 출생 연도  | 연속형   |
| 사망 연도    | 사망 작가 = 작가가 사망한 연도, 생존 작가 = 0                    | "     |
| 나이       | 사망 작가 = 사망 시 작가의 나이<br>생존 작가 = 판매 시점에서 작가의 나이    | "     |
| 사망 여부    | 판매 시점에서 사망 작가 = 1, 생존 작가 = 0                     | 범주형   |
| 성별       | 남성 작가 = 1, 여성 작가 = 0                             | "     |
| 출신 학교    | 서울대/홍익대에서 학위를 받은 작가 = 1, 그 외 작가 = 0              | "     |
| 유학 여부    | 유학 경험이 있는 작가 = 1, 그 외 작가 = 0                     | "     |
| 작품 판매 횟수 | 2014년부터 2017년 동안 개별 작가의 판매 작품 횟수                 | 연속형   |
| 평균 낙찰가   | $\ln(2014\text{-}2017\text{년 동안 개별 작가의 평균 낙찰가})$ | "     |
| 높이       | 작품의 세로 길이(cm)                                    | "     |
| 너비       | 작품의 가로 길이(cm)                                    | "     |
| 판화       | 판화 작품 = 1, 그 외 = 0                               | 범주형   |
| 캔버스      | 캔버스 = 1, 그 외 = 0                                 | "     |
| 종이       | 종이 = 1, 그 외 = 0                                  | "     |
| 한지       | 한지 = 1, 그 외 = 0                                  | "     |
| 섬유       | 섬유 = 1, 그 외 = 0                                  | "     |
| 기타 바탕 재료 | 기타 바탕 재료 = 1, 그 외 = 0                            | "     |
| 유채       | 유채 = 1, 그 외 = 0                                  | "     |
| 아크릴      | 아크릴 = 1, 그 외 = 0                                 | "     |
| 채색       | 채색 = 1, 그 외 = 0                                  | "     |
| 수묵       | 수묵 = 1, 그 외 = 0                                  | "     |
| 잉크       | 잉크 = 1, 그 외 = 0                                  | "     |
| 과슈       | 과슈 = 1, 그 외 = 0                                  | "     |
| 안료       | 안료 = 1, 그 외 = 0                                  | "     |
| 혼합 재료    | 혼합 재료 = 1, 그 외 = 0                               | "     |
| 기타 사용 재료 | 기타 사용 재료 = 1, 그 외 = 0                            | "     |
| 경매 유형    | 온라인 경매 작품 = 1, 오프라인 경매 작품 = 0                    | "     |

〈Table 3〉 변수간 상관관계

|        | 낙찰가      | 감정 추정가   | 평균 낙찰가   | 판매 횟수    | 출생 연도   | 나이       | 사망 여부    | 길이       | 높이       | 경매 유형 |
|--------|----------|----------|----------|----------|---------|----------|----------|----------|----------|-------|
| 낙찰가    | 1        | -        | -        | -        | -       | -        | -        | -        | -        | -     |
| 감정 추정가 | 0.98***  | 1        | -        | -        | -       | -        | -        | -        | -        | -     |
| 평균 낙찰가 | 0.71***  | 0.68***  | 1        | -        | -       | -        | -        | -        | -        | -     |
| 판매 횟수  | 0.3***   | 0.28***  | 0.54***  | 1        | -       | -        | -        | -        | -        | -     |
| 출생연도   | -0.1***  | -0.07*** | -0.2***  | -0.22*** | 1       | -        | -        | -        | -        | -     |
| 나이     | 0.01     | 0        | 0.11***  | 0.31***  | -0.7*** | 1        | -        | -        | -        | -     |
| 사망 여부  | 0.02     | 0        | 0.09***  | 0        | -0.7*** | 0.28***  | 1        | -        | -        | -     |
| 길이     | 0.39***  | 0.43***  | 0.11***  | -0.06*** | 0.15*** | -0.13*** | -0.15*** | 1        | -        | -     |
| 높이     | 0.38***  | 0.41***  | 0.07***  | -0.05*** | 0.19*** | -0.14*** | -0.18*** | 0.69***  | 1        | -     |
| 경매 유형  | -0.76*** | -0.72*** | -0.55*** | -0.23*** | 0.15*** | -0.03**  | -0.05*** | -0.25*** | -0.24*** | 1     |

\*p < 0.05, \*\*p < 0.01, \*\*\*p < 0.001

격결정요인의 영향력은 다르므로(Park and Shin, 2012; Jang and Park, 2019) 온라인 경매와 오프라인 경매로 경매 유형을 구분하였다. 분석에 사용된 모든 범주형 변수는 원-핫 인코딩(one-hot-encoding) 처리하였다.

각 변수의 상관관계는 아래 〈Table 3〉과 같다. 지면의 한계로 인해 작품의 소재 및 작가특성요인의 일부(작가 성별, 출신 학교, 유학 여부)는 〈Table 3〉에서 제외하였다. 낙찰가와 변수 간의 상관계수를 살펴보면, 감정 추정가는 변수 중 가장 높은 0.98이며 유의수준 0.1% 내에서 유의하였다. 특히 감정 추정가와 낙찰가는 다른 변수와의 계수 방향 및 크기가 서로 유사한 것으로 나타났다. 이를 통해 감정 추정가가 작품 가격에 대한 우수한 예측자임을 추측할 수 있다. 작가의 평균 판매가와 낙찰가와의 상관관계 또한 0.71로 높은 수준인 것으로 나타났다. 반면 경매 유형의 경우 낙찰가와의 상관관계가 -0.76으로 큰 값을 가지는 것으로 나타나 온라인 경매 작품은 낮은 낙찰가를 가질 것으로 예상할 수 있다.

## IV. 결과 분석

### 4.1 모형 구축


본 절에서는 모형을 최적화하기 위해 모형 별 초매개변수를 미세 조정한다. 각 격자 조합 별 손실 함수는 RMSE다. 본 연구가 고려한 초매개변수의 목록을 다음 〈Table 4〉로 제시한다.

#### 4.1.1 랜덤 포레스트(RF)

〈Figure 1〉을 보면, *mtry*가 3에 이를 때까지 오차가 급격히 감소하는 것을 확인할 수 있다. 최종적으로 RF는 *ntree*가 2,000, *mtry*는 9일 때 RMSE가 0.488로 가장 낮았다. 반면 고려된 *ntree* 범위 내에서는 트리 개수에 따른 예측력 차이가 미미하였다.

〈Table 4〉 모형 별 초 매개변수

| 모형             | 명칭                               | 정의                              | 조절 수준                       |
|----------------|----------------------------------|---------------------------------|-----------------------------|
| 랜덤 포레스트(RF)    | <i>ntree</i>                     | 성장시퀀트 트리의 개수                    | 100, 500, 1,000, 2,000      |
|                | <i>mtry</i>                      | 노드에 투입될 변수 후보의 개수               | 1 ~ 15                      |
| 그라디언트 부스팅(GBM) | <i>shrinkage</i> ( $\lambda$ )   | 잔차 추정의 학습 속도를 제어하는 수축 매개변수      | 0.001, 0.01, 0.1, 0.5       |
|                | <i>interaction_depth</i> ( $d$ ) | 각 트리의 분할 깊이                     | 1 ~ 12                      |
|                | <i>n.tree</i>                    | 성장시퀀트 트리의 개수                    | 1,000, 3,000, 5,000, 10,000 |
| XGboost (XGB)  | <i>eta</i>                       | 수축 매개변수로 GBM의 $\lambda$ 와 동일함   | 0.001, 0.01, 0.1, 0.5       |
|                | <i>gamma</i>                     | 트리 분할 시 정보 획득의 수준을 조정하는 최소 손실 값 | 0, 0.1, 0.5, 1              |
|                | <i>max_depth</i> ( $d$ )         | 각 트리의 분할 깊이                     | 1 ~ 12                      |
|                | <i>nrounds</i>                   | 성장시퀀트 트리의 개수                    | 1,000, 3,000, 5,000, 10,000 |
| k-최근접 이웃(kNN)  | <i>k</i>                         | 근접한 데이터의 개수                     | 1 ~ 30                      |



〈Figure 1〉 랜덤 포레스트의 초 매개변수 미세 조정 결과

#### 4.1.2 그라디언트 부스팅(GBM)

〈Figure 2〉는 GBM의 미세 조정 결과다. GBM은  $n.tree=10,000$ ,  $\lambda=0.01$ ,  $d=12$ 일 때 RMSE가 0.485로 가장 낮았다. 전반적으로 분할 수준이 클수록 오차가 낮아지는 것으로 나타났다.  $\lambda$ 가 0.001일 때는 트리 개수가 많을수록 오차가 낮은 반면,  $\lambda$ 가 0.5일 때는 트리 개수가 많을수록 오차가 반대로

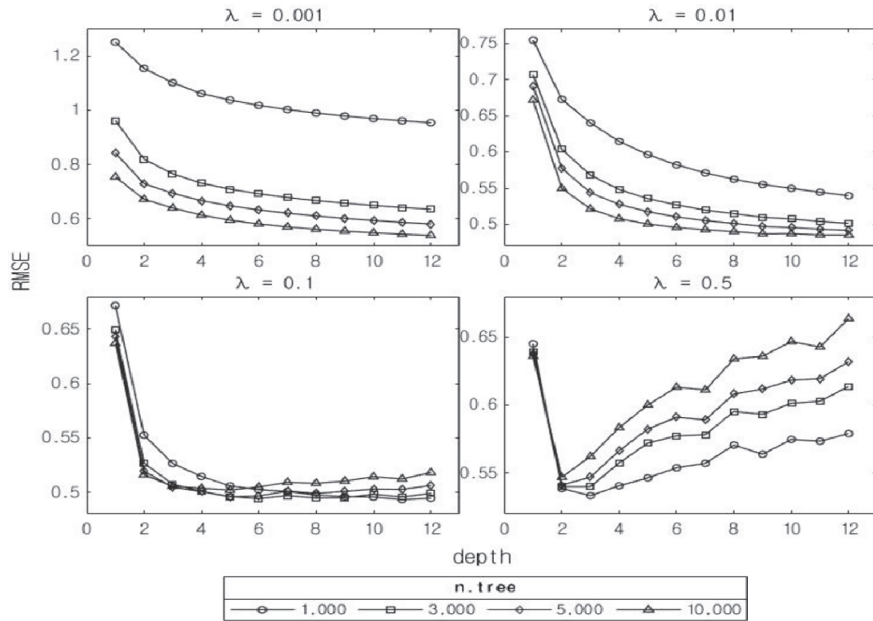
높은 것을 〈Figure 2〉에서 확인할 수 있다.

#### 4.1.3 XGBoost(XGB)

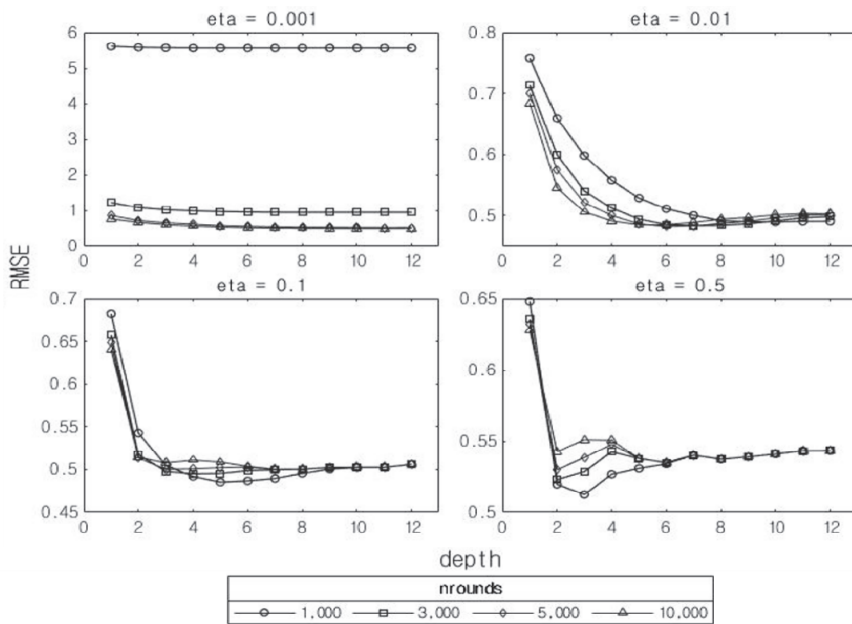
XGB의 경우,  $eta=0.01$ ,  $gamma=0$ ,  $nrounds=5,000$ ,  $depth=6$ 일 때 RMSE가 0.482로 가장 낮았다. 다음 〈Figure 3〉은  $gamma=0$ 에서 XGB의 미세 조정 결과다. XGB가 GBM을 기반으로 하는 만큼, 〈Figure 2〉와 유사하게 분할 수준이 클수록 오차는 낮아지는 것으로 나타났다. 마찬가지로  $eta$ 가 작을 때는 많은 학습량을 요구하는 반면,  $eta$ 가 1에 가까워질수록 트리 개수의 과도한 증가는 예측을 감소시키는 것으로 나타났다.

#### 4.1.4 k-최근접 이웃(kNN)

kNN의 경우  $k$ 가 5일 때 가장 낮은 RMSE 0.578를 기록하였다.  $k$ 가 극단적으로 작을 때에는 결과가 가장 근접한 단 몇 개의 관측치의 속성값과 일치해가므로, 이 경우 지역적 특성이 지나치게 반영됨




<Figure 2> 그래디언트 부스팅의 초 매개변수 미세 조정 결과



<Figure 3> XGBoost의 초 매개변수 미세 조정 결과



으로써 과대적합이 일어나게 된다. 반대로  $k$ 값이 7을 넘어서면서 오차가 계속 상승하는 것은 예측 값이 점차 전체 데이터의 평균값으로 회귀하면서 발생하는 과소 적합에 기인한다.



〈Figure 4〉 kNN의 초 매개변수 미세 조정 결과

#### 4.2 기본 모형 평가

감정 추정가를 제외한 〈Table 2〉의 모든 변수를 투입하여 기본 모형을 구축하였다. 기본 모형은 4장 1절에서 가장 낮은 예측 오차를 보인 초 매개변수 조합이 적용되었다. 작품 가격 별 모형의 예측 결과를 〈Table 5〉로 제시한다. 작품의 가격 수준은 '1억 원 이상(A)', '1억 원 미만~5천만 원 이상(B)', '5천만 원 미만~1천만 원 이상(C)', '1천만 원 미만~5백만 원 이상(D)', '5백만 원 미만~1백만 원 이상(E)', '1백만 원 미만(F)' 총 여섯 범위로 구분하였다.

전체 작품을 대상으로 할 때, RMSE는 GBM이 0.548로 가장 낮았으며, MAE는 XGB가 0.403으로 가장 낮았다. 다만 두 오차 지표 모두 트리 모형 간 예측 오차의 차이는 미미하였다. 같은 비모수 모형인 kNN은 모든 가격 범위에서 결정 트리 모형보

〈Table 5〉 가격 수준 별 모형의 예측 오차

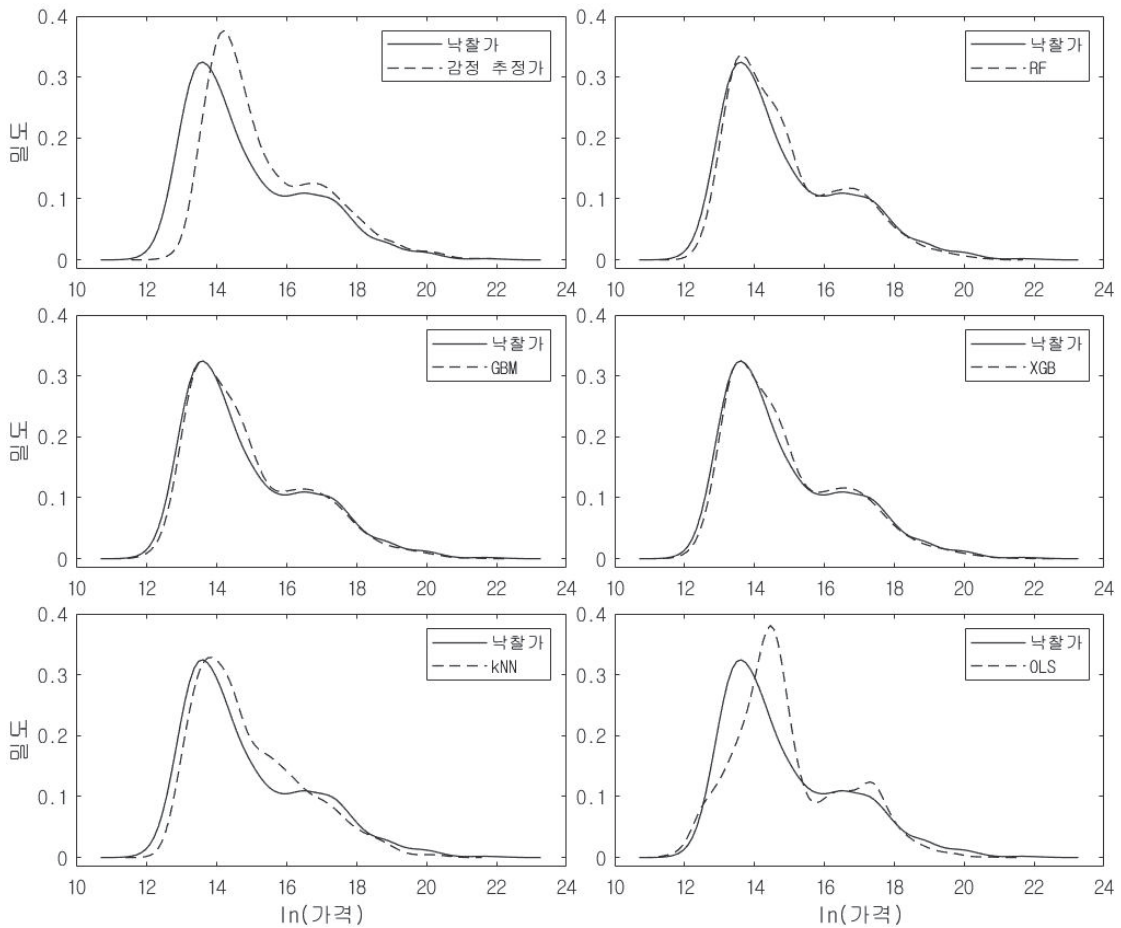
| 오차 지표 | 모형     | 전체    | A     | B             | C              | D              | E              | F     |
|-------|--------|-------|-------|---------------|----------------|----------------|----------------|-------|
|       |        |       | ≥1억   | < 1억<br>≥ 5천만 | < 5천만<br>≥ 1천만 | < 1천만<br>≥ 5백만 | < 5백만<br>≥ 1백만 | < 1백만 |
| RMSE  | RF     | 0.552 | 0.936 | 0.582         | 0.579          | 0.646          | 0.505          | 0.488 |
|       | GBM    | 0.548 | 0.778 | 0.606         | 0.568          | 0.657          | 0.529          | 0.481 |
|       | XGB    | 0.549 | 0.787 | 0.586         | 0.576          | 0.655          | 0.536          | 0.476 |
|       | kNN    | 0.666 | 0.901 | 0.722         | 0.655          | 0.738          | 0.623          | 0.655 |
|       | OLS    | 0.754 | 1.410 | 0.787         | 0.725          | 0.770          | 0.605          | 0.774 |
|       | 감정 추정가 | 0.636 | 0.307 | 0.377         | 0.415          | 0.627          | 0.625          | 0.782 |
| MAE   | RF     | 0.408 | 0.722 | 0.452         | 0.387          | 0.481          | 0.395          | 0.369 |
|       | GBM    | 0.406 | 0.578 | 0.457         | 0.396          | 0.474          | 0.409          | 0.364 |
|       | XGB    | 0.403 | 0.568 | 0.439         | 0.386          | 0.486          | 0.411          | 0.360 |
|       | kNN    | 0.489 | 0.690 | 0.560         | 0.447          | 0.531          | 0.471          | 0.487 |
|       | OLS    | 0.576 | 1.163 | 0.619         | 0.517          | 0.613          | 0.460          | 0.637 |
|       | 감정 추정가 | 0.542 | 0.263 | 0.327         | 0.351          | 0.521          | 0.530          | 0.718 |
| 표본 수  |        | 2,535 | 113   | 91            | 432            | 181            | 880            | 838   |

다 오차가 높았으며 OLS는 RMSE 0.754, MAE 0.576으로 고려된 모형 중 성능이 가장 떨어지는 것으로 나타났다. 특징적인 점은 시가가 낮은 작품일 수록 기계 학습 모형의 오차가 대체로 낮아지고, 반대로 감정 추정가의 오차는 높아졌다는 점이다. 고가 작품인 A 구간에서 감정 추정가는 RMSE 0.307, MAE 0.263으로 가격 범위 중에 가장 높은 예측력을 보였으나, D 구간에서는 감정 추정가의 MAE는 0.521로 결정 트리 모형의 MAE(RF=0.481, GBM

=0.474, XGB=0.486)보다 높았다. 이후 E, F 구간에서 기계 학습 모형의 RMSE와 MAE는 감정 추정가보다 모두 낮은 것으로 나타났다. 특히 1백만 원 미만의 작품에서 XGB의 MAE는 0.360으로 감정 추정가 MAE의 약 50% 수준이었다.

예측 오차만으로는 추정된 값의 분포 형태를 파악할 수 없다. 따라서 모형의 예측 값에 대한 커널 밀도 곡선을 추정하여 <Figure 5>로 제시한다.

<Figure 5>의 좌측 상단 그래프를 보면, 감정 추



<Figure 5> 모형 및 감정 추정가의 커널 밀도 추정 결과

평가의 밀도 곡선은 실제 낙찰가에서 우측으로 평행 이동한 형태를 보이다가 가격 수준이 높아질수록 실제 가격 밀도와 일치해가는 것을 확인할 수 있다. 이는 저가 작품일수록 예측 오차가 증가하는 <Table 5>의 결과와 일치한다. 즉, 저가 작품에 대한 높은 오차는 경매사의 과대평가에 원인이 있음을 보여준다. 반면 기계 학습 모형의 밀도 곡선 형태는 낙찰가와 거의 근사한 것을 확인할 수 있다. 특히 부스팅 계열인 GBM과 XGB의 곡선이 낙찰가와 가장 유사한 형태를 보였다. 이는 기계학습 모형이 발생가능한 추정 편향으로부터 강건함을 의미한다. 다만 작품 가격이 높아질수록 감정 추정가의 밀도 곡선이 낙찰가에 수렴해 간 것과 달리, 기계 학습의 밀도 곡선은 가격이 일정 수준을 넘어서면 낙찰가보다 하향하다 끝에서는 끊어지는 것으로 나타났다. 이는 평균을 이용하는 통계 모형의 한계에 기인하며 고가 작품에 대해서는 감정 평가의 신뢰도가 예측 모형보다 높음을 의미한다. <Table 5>에서 가장 정확도가 낮았던 OLS 모형의 밀도 곡선은 다른 모형에 비해 낙찰가에서 크게 벗어나는 형태를 보였다.

#### 4.3 감정 추정가 결합 모형 평가

본 절에서는 기본 모형에 전문가 평가 가치를 반영한 결합 모형의 예측력을 평가한다. 전문가 평가 가치는 감정 추정가의 자연 로그 값으로 대표되며, 해당 값을 추가하여 기존 모형을 재구축 하였다. 초매개변수의 수준은 전과 동일하게 격자 탐색으로 결정하였다.

기본 모형과 감정 추정가를 반영한 결합 모형의 예측 오차와 기본 모형 대비 변화율을 <Table 6>으로 제시한다. <Table 6>을 보면 모든 결합 모형의 예측 오차가 기존 모형에 비해 현저히 낮아진 것을

확인할 수 있다. 전체 작품에 대해서 결정 트리 기반 결합 모형은 감정 추정가보다 RMSE는 38~39%, MAE는 약 45%가량 낮았다. RF는 RMSE 0.387, MAE는 0.293으로 감정 추정가를 포함하여 모든 모형들 중 가장 우수한 성능을 보였다. 특히 F 구간에서 결정 트리 결합 모형의 RMSE가 기본 모형에 비해 15.4%~18.9% 감소한 것과 달리, A구간에서는 62.6%~67.3%까지 감소하여 고가 작품에 대한 감정 추정가의 높은 신뢰도가 결합 모형에 반영되었음을 추정할 수 있다. 또한 <Table 5>에서 가장 저조한 예측력을 보인 OLS는 감정 추정가를 반영함으로써 오차가 48%가량 감소하여 고려된 모형들 중 가장 크게 성능이 개선되었다.

<Figure 6>를 통해 감정 추정가와 예측 모형의 예측력 차이를 한 눈에 확인할 수 있다. 그래프를 가로지르는 파선은 100%로 환산된 감정 추정가의 RMSE다. <Figure 6>에서 (a)는 기본 모형, (b)는 결합 모형의 예측력을 나타낸다. <Figure 6>의 (a), (b) 모든 경우에서 가격 수준이 낮아질수록 모형의 예측 오차가 감정 추정가 대비 낮아지는 것을 확인할 수 있다. 특히 <Figure 6>(a)와 달리, <Figure 6>(b)에서는 A 구간의 RF를 제외한 모든 결정 트리 모형과 OLS의 그래프가 파선 아래에 위치한 것을 확인할 수 있다. 본 절의 결과는 전문가 평가와 모형 평가를 통합하여 운용함으로써 감정 평가의 정확도를 향상시킬 수 있음을 보여준다.

<Figure 7>은 결합 모형의 커널 밀도 추정 결과를 보여준다. 기본 모형과 비교할 때 가장 큰 변화는 고가 작품에서 모형의 밀도 곡선이 실제 가격에 근사하고 곡선의 오른쪽 꼬리부분이 실제 가격과 거의 동일해졌다는 점이다. 특히 선형 회귀의 경우 밀도 곡선의 형태가 실제 값에서 크게 벗어났던 <Figure 5>와 달리 기계 학습과 동일한 밀도 형태를 보였다.


〈Table 6〉 모형의 예측 오차 변화량

| 오차 지표  | 모형     | 전체     | A      | B             | C              | D              | E              | F      |
|--------|--------|--------|--------|---------------|----------------|----------------|----------------|--------|
|        |        |        | ≥1억    | < 1억<br>≥ 5천만 | < 5천만<br>≥ 1천만 | < 1천만<br>≥ 5백만 | < 5백만<br>≥ 1백만 | < 1백만  |
| RMSE   | RF     | 0.387  | 0.350  | 0.298         | 0.318          | 0.489          | 0.397          | 0.396  |
|        | 오차 변화율 | -30.0% | -62.6% | -48.8%        | -45.1%         | -24.4%         | -21.3%         | -18.9% |
|        | GBM    | 0.390  | 0.291  | 0.292         | 0.327          | 0.476          | 0.406          | 0.403  |
|        | 오차 변화율 | -28.8% | -62.6% | -51.8%        | -42.5%         | -27.7%         | -23.4%         | -16.3% |
|        | XGB    | 0.390  | 0.257  | 0.290         | 0.333          | 0.493          | 0.404          | 0.403  |
|        | 오차 변화율 | -28.9% | -67.3% | -50.6%        | -42.2%         | -24.7%         | -24.6%         | -15.4% |
|        | kNN    | 0.542  | 0.560  | 0.498         | 0.446          | 0.572          | 0.531          | 0.593  |
|        | 오차 변화율 | -18.6% | -37.8% | -30.9%        | -31.9%         | -22.5%         | -14.7%         | -9.6%  |
|        | OLS    | 0.389  | 0.289  | 0.330         | 0.323          | 0.528          | 0.398          | 0.394  |
|        | 오차 변화율 | -48.3% | -79.5% | -58.1%        | -55.5%         | -31.5%         | -34.3%         | -49.1% |
| 감정 추정가 | 0.636  | 0.307  | 0.377  | 0.415         | 0.627          | 0.625          | 0.782          |        |
| MAE    | RF     | 0.293  | 0.220  | 0.203         | 0.233          | 0.348          | 0.311          | 0.314  |
|        | 오차 변화율 | -28.1% | -69.5% | -55.1%        | -39.8%         | -27.7%         | -21.3%         | -14.9% |
|        | GBM    | 0.296  | 0.191  | 0.204         | 0.234          | 0.351          | 0.319          | 0.317  |
|        | 오차 변화율 | -27.0% | -67.0% | -55.5%        | -40.8%         | -25.8%         | -22.0%         | -13.0% |
|        | XGB    | 0.295  | 0.173  | 0.204         | 0.236          | 0.356          | 0.315          | 0.317  |
|        | 오차 변화율 | -26.8% | -69.6% | -53.6%        | -38.9%         | -26.7%         | -23.3%         | -11.7% |
|        | kNN    | 0.422  | 0.407  | 0.376         | 0.343          | 0.446          | 0.422          | 0.465  |
|        | 오차 변화율 | -13.7% | -41.0% | -32.9%        | -23.3%         | -15.9%         | -10.4%         | -4.5%  |
|        | OLS    | 0.297  | 0.193  | 0.228         | 0.239          | 0.385          | 0.309          | 0.316  |
|        | 오차 변화율 | -48.5% | -83.4% | -63.2%        | -53.8%         | -37.2%         | -32.9%         | -50.3% |
| 감정 추정가 | 0.542  | 0.263  | 0.327  | 0.351         | 0.521          | 0.53           | 0.718          |        |

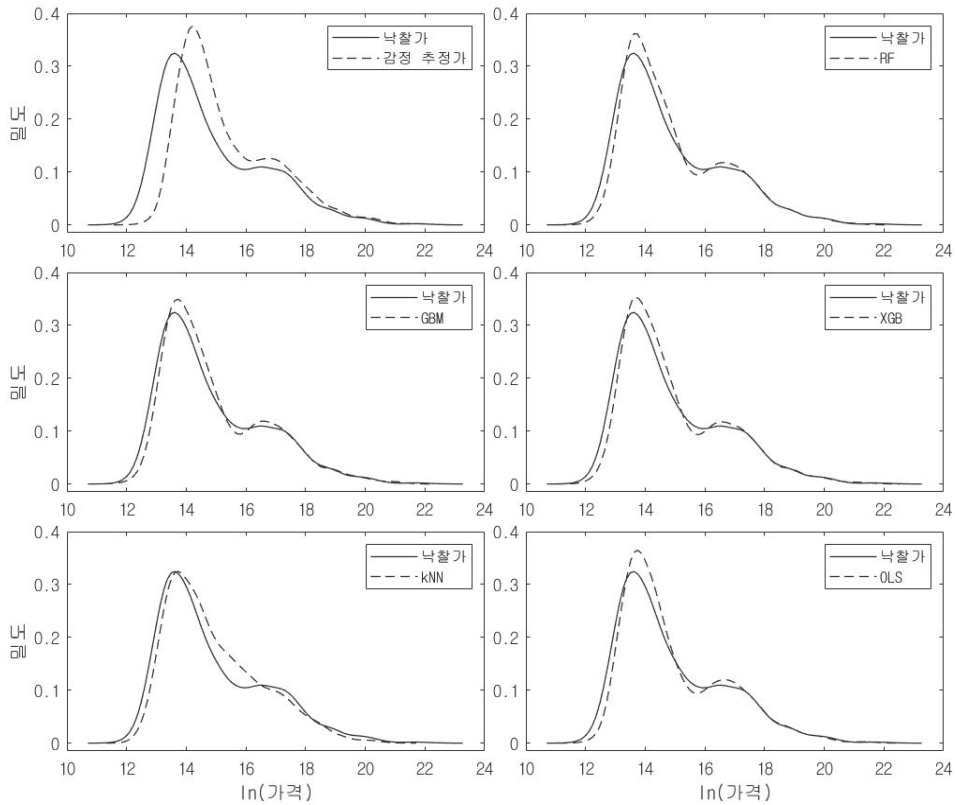
\* 오차 변화율(%): ((결합 모형 예측 오차 / 기본 모형 예측 오차)-1)\*100

다만 고가 작품 외에 경우에는 결합 모형의 곡선이 기본 모형보다 우측으로 어긋나는 형태를 보였다. 이는 감정 추정가에 존재하는 편향이 결합 모형에 일부 반영되었기 때문인 것으로 추측된다. 마찬가지로 오른쪽 꼬리가 여전히 일정 지점부터는 끊어지는 것으로 나타나 초고가 작품의 가격을 예측하는 데 있어서는 단일 감정 평가가 효과적일 것으로 보인다.

모형 평가 결과, 기계 학습은 저가 작품일수록 예측 성능이 비교적 우수하며 감정 평가 과정에서 반영될 수 있는 추정 편향으로부터 강건하다는 것을 알 수 있었다. 이는 기계 학습이 감정 평가에서 발생 가능한 편향을 교정하고, 가격 수준에 따라 구매자와 판매자 모두에게 효율적인 가격 추정 도구로 활용될 수 있음을 시사한다.



〈Figure 6〉 가격 수준 별 모형의 RMS



〈Figure 7〉 결합 모형의 커널 밀도 추정 결과



#### 4.4 경매 유형에 따른 예측력 비교

온라인 미술 시장은 시장에 대한 낮은 진입장벽으로 신규 구매층을 확대해가고 있다. 다만 미술품 구매 경험이 적은 신규 구매자에게 있어 앞서 확인한 감정 추정가의 편향성은 구매자의 합리적인 의사결정을 방해하는 요인이 될 수 있다. 또한 3장 2절의 기술통계에서 확인한 대로, 온라인 경매 시장에서는 오프라인 경매에 비해 저가 작품이 주로 판매된다. 본 절에서는 경매 유형에 따른 모형의 예측 오차를

비교한다. 이를 위해 데이터를 경매 유형 별로 분리한 후, 전과 동일한 방식으로 모형을 구축하였다. 데이터를 분리한 이유는 경매 유형 구분 없이 혼합된 데이터를 사용함으로써 발생할 수 있는 편향의 영향력을 최소화하기 위함이다.

〈Table 7〉은 데이터를 전체, 온라인 경매, 오프라인 경매로 구분하여 구축한 모형의 예측 오차다. 분석 결과, 감정 추정가의 RMSE는 오프라인 경매에서 0.372이었으나 온라인 경매에서는 0.707로 현저히 높은 것으로 나타났다. 기본 결정 트리 모형은

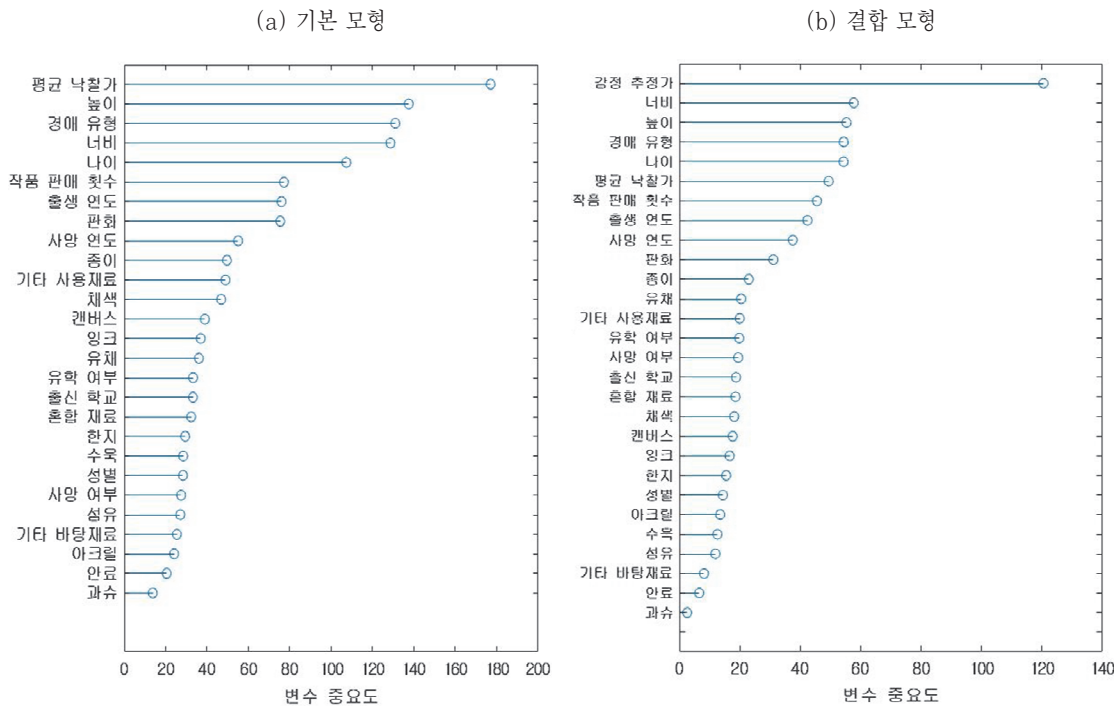
〈Table 7〉 경매 유형 별 예측 오차

| 오차 지표     | 모형        | 기본 모형  |        |        | 결합 모형 |       |        |
|-----------|-----------|--------|--------|--------|-------|-------|--------|
|           |           | 전체     | 온라인    | 오프라인   | 전체    | 온라인   | 오프라인   |
| RMSE      | RF        | 0.552  | 0.551  | 0.576  | 0.387 | 0.416 | 0.304  |
|           | 추정가 대비(%) | 86.8%  | 78.0%  | 154.9% | 60.8% | 58.9% | 81.7%  |
|           | GBM       | 0.548  | 0.543  | 0.576  | 0.390 | 0.417 | 0.307  |
|           | 추정가 대비(%) | 86.1%  | 76.9%  | 155.0% | 61.3% | 59.0% | 82.5%  |
|           | XGB       | 0.549  | 0.551  | 0.569  | 0.390 | 0.419 | 0.298  |
|           | 추정가 대비(%) | 86.3%  | 78.0%  | 153.2% | 61.4% | 59.3% | 80.2%  |
|           | kNN       | 0.666  | 0.652  | 0.655  | 0.542 | 0.483 | 0.519  |
|           | 추정가 대비(%) | 104.7% | 92.3%  | 176.3% | 85.3% | 68.3% | 139.7% |
|           | OLS       | 0.754  | 0.714  | 0.756  | 0.389 | 0.410 | 0.305  |
| 추정가 대비(%) | 118.4%    | 101.1% | 203.4% | 61.2%  | 58.0% | 82.0% |        |
|           | 감정 추정가    | 0.636  | 0.707  | 0.372  | 0.636 | 0.707 | 0.372  |
| MAE       | RF        | 0.408  | 0.407  | 0.417  | 0.293 | 0.321 | 0.222  |
|           | 추정가 대비(%) | 75.3%  | 65.5%  | 131.6% | 54.1% | 51.6% | 69.9%  |
|           | GBM       | 0.406  | 0.403  | 0.423  | 0.296 | 0.323 | 0.228  |
|           | 추정가 대비(%) | 74.9%  | 64.8%  | 133.4% | 54.7% | 51.9% | 72.0%  |
|           | XGB       | 0.403  | 0.404  | 0.409  | 0.295 | 0.323 | 0.223  |
|           | 추정가 대비(%) | 74.4%  | 65.0%  | 129.1% | 54.5% | 52.0% | 70.3%  |
|           | kNN       | 0.489  | 0.468  | 0.490  | 0.422 | 0.368 | 0.395  |
|           | 추정가 대비(%) | 90.3%  | 75.3%  | 154.5% | 77.9% | 59.2% | 124.6% |
|           | OLS       | 0.576  | 0.555  | 0.565  | 0.297 | 0.316 | 0.229  |
| 추정가 대비(%) | 106.3%    | 89.3%  | 178.4% | 54.8%  | 50.9% | 72.4% |        |
|           | 감정 추정가    | 0.542  | 0.622  | 0.317  | 0.542 | 0.622 | 0.317  |

온라인 모형이 오프라인 모형보다 예측력이 높았으며 예측오차의 절대값은 경매 유형에 따라 큰 차이를 보이지 않았다. 온라인 기본 모형은 감정 추정가보다 예측력이 우수하였으며 특히 GBM은 감정 추정가 MAE의 64.8% 수준이었다. 반면 결합 트리 모형의 경우 오프라인 모형이 온라인 모형보다 예측오차가 낮았으며 온라인, 오프라인 경매 모두 감정 추정가보다 예측력이 우수하였다. 해당 결과는 기계 학습을 이용한 가격 평가 기법이 온라인 미술 시장에서 활용 가능성이 높음을 보여준다. 특히 거래량이 크게 증대되어가는 온라인 경매 시장에서 감정사가 모형 평가를 효과적으로 운용할 있다면 단기간에 예측력과 평가 신뢰도를 보완하여 평가의 효율성을 높일 수 있을 것이다.

#### 4.5 변수 중요도 분석 결과

일부 변수는 모형의 예측력 개선에 기여하지 못하거나 모형의 복잡성을 높이기도 한다. 본 절에서는 본 연구가 고려한 변수들의 중요도 측정 결과를 제시한다. <Figure 8>은 랜덤 포레스트가 모델링 과정에서 계산한 변수 중요도 결과다. <Figure 8>(a), (b)에서 작가의 명성, 나이, 작품 크기, 판매 유형이 예측 정확도를 비교적 크게 좌우하는 것으로 나타났다. 그중 <Figure 8>(a)에서는 작가의 평균 낙찰가(177.0)가 오차를 가장 크게 감소시키는 것으로 나타났다. 작품의 크기나 경매 유형이 고정된 값을 가지는 점을 고려할 때, 해당 결과는 작가의 위신과 관련한 변수 개발이 모형의 예측 성능 향상에 핵심



(Figure 8) 랜덤 포레스트의 변수 중요도 계산 결과

적 역할을 할 것임을 보여준다. 반면 <Figure 8>(b)에서는 각 변수 중요도가 기본 모형보다 낮아진 것을 확인할 수 있다. 대신 감정 추정가의 변수 중요도(120.4)가 두 번째 중요 변수로 산출된 너비 변수의 중요도(57.7)보다 두 배 이상 높은 것으로 나타났다. 이는 전문가의 감정 과정에 본 연구가 고려한 변수들의 영향력이 반영되었기 때문인 것으로 보인다.

## V. 결론

인간의 창작물인 미술품은 각각이 이질적이며 효용 가치는 개인마다 다르다. 이로 인해 전문성을 인정받은 감정인의 평가 가치는 사실상 작품의 기준 가격으로 받아들여진다. 다만 감정 평가는 소수의 견에 의존할 수밖에 없으며 늘어가는 거래량을 충족하기에는 평가 방식에 있어 물리적인 한계를 가진다. 이러한 배경에서 본 연구는 미술품 가격 예측 모형으로서 기계 학습의 한 갈래인 결정 트리 기반 알고리즘을 이용하였다.

본 분석을 위해 서울 옥션과 케이 옥션에서 이루어진 12,105건의 국내 미술품 경매 데이터를 수집하였다. 사용된 결정 트리 기반 알고리즘은 랜덤 포레스트, 그래디언트 부스팅, XG부스트이며 모형의 성능 비교를 위해 선형 회귀와 k-최근접 이웃 모형을 추가적으로 구축하였다. 모형 구축에는 2009년부터 2017년까지의 경매 데이터가 사용되었으며 구축한 모형을 이용하여 2018년 거래된 미술품의 가격을 예측하였다. 이후 예측 오차와 밀도 추정 결과를 토대로 판매 가격에 대한 모형과 감정 추정가의 예측력을 비교하였다. 본 연구는 결과는 다음과 같다.

첫째, 경매사의 감정 추정가에는 편향 위험이 존

재한다. 경매사는 내부 심사를 거쳐 평가한 작품의 가격을 범위의 형태로 제시한다. 본 연구는 해당 가격 범위의 중간 값을 감정 추정가의 대표 값으로 사용하여 실제 낙찰가와와의 예측 오차를 계산하였다. 분석 결과, 작품 가격이 낮을수록 감정 추정가의 예측 오차는 상승하는 것으로 나타났으며, 감정 추정가의 커널 밀도 곡선은 저가 작품일수록 실제 판매가 곡선에서 우측으로 평행 이동하는 형태를 보였다. 이후 온라인 경매 시장에서 중저가 작품이 판매되는 점을 고려하여 경매 유형 별로 감정 추정가의 예측 오차를 계산한 결과, 온라인 경매 시장에서 감정 추정가의 RMSE는 0.707로 오프라인 경매 0.372보다 1.9배 가량 높은 것으로 나타났다. 해당 결과는 경매사의 감정 추정가는 편향될 위험이 있으며 특히 중저가 작품이 판매되는 온라인 미술 시장에서 공개된 감정 추정가를 한계적으로 신뢰할 수 있음을 보여준다.

둘째, 기계 학습 모형은 감정 추정가와 반대로 저가 작품일수록 높은 예측 정확도를 보였다. 공개된 작품 정보를 변수로 하는 예측 모형을 구축하여 실제 판매가와와의 오차를 계산한 결과, 저가 작품일수록 기계 학습의 예측 오차는 낮아지는 것으로 나타났다. 그중 결정 트리 기반 모형은 500만원 미만인 작품 가격을 감정 추정가보다 정확히 예측하였다. 특히 100만원 미만 작품에 대한 XG부스트의 RMSE는 0.476으로 감정 추정가 0.782보다 39%가량 낮은 것으로 나타났다. 또한 저가 작품에서 편향성이 존재했던 감정 추정가와 달리, 결정 트리 기반 모형의 커널 밀도 곡선 형태는 가격 수준과 관계없이 실제 가격의 밀도 곡선과 거의 동일하였다. 선형 회귀의 RMSE는 감정 추정가보다 18%가량 높은 0.774로 나타나 고려된 모형들 중 가장 낮은 예측력을 보였으며 커널 밀도 곡선 또한 실제 가격으로부터 크게 벗어난 형태를 보였다. 이후 경매 유형 별로 모형을

구축하여 평가한 결과, 결정 트리 기반 모형은 온라인 경매에서 감정 추정가보다 작품 가격을 정확히 예측하였다. 해당 결과는 기계 학습이 감정 추정가보다 추정 편향으로부터 강건하며 중저가 작품이 주로 거래되는 온라인 미술 시장에서 활용 가능성이 높음을 보여준다.

셋째, 전문가의 평가 가치를 예측 모형에 반영함으로써 모형의 예측력을 개선할 수 있다. 감정 추정가에 자연 로그를 취하여 모형에 투입한 결과, 모든 모형의 예측 오차는 현저히 감소하였다. 그중 결정 트리 기반 모형은 추정가 투입 전에 비해 RMSE가 28.8~30.0%가량 감소하였다. 특히 고가 작품에 대해 낮은 예측력을 보였던 기본 모형과 달리, 감정 추정가를 결합한 결정 트리 모형과 선형 회귀 모형은 가격 범위와 경매 유형에 관계없이 감정 추정가보다 정확히 가격을 예측하였다. 다만 1억원 이상 작품에 대한 랜덤 포레스트 결합 모형의 RMSE만은 감정 추정가보다 15%가량 높은 것으로 나타난다. 해당 결과는 감정 평가와 통계 모형의 통합적 운용이 미술품 가격 평가의 정확도를 높이는 하나의 방법이 될 수 있음을 보여준다.

본 연구의 의의는 다음과 같다. 첫째, 통계 모델을 이용하여 미술품 자동화 평가의 효과성을 실증 분석하였다. 본 연구가 조사한 범위 내에서 미술품에 대해 기계 학습과 인간의 평가 가치를 비교한 사례는 Aubry et al.(2019)에 한정되며 결정 트리 기반 모형과 감정 추정가를 비교 분석한 사례는 우리가 아는 한 거의 없었다. 공개적으로 신뢰할 수 있는 미술품 가격의 부재가 잠재 구매자의 의사결정에 큰 걸림돌이 되는 만큼, 공개된 데이터만을 이용하여 구축한 가격 모형이 높은 예측력을 보인다면 미술품 가격의 불투명성을 해소하여 시장의 유동성을 높일 수 있을 것이다. 전문가 평가 가치에 준하는 추정 가

격을 주어진 데이터만을 이용해 일시에 산출하였다는 점에서 본 연구의 실용적인 의의를 찾을 수 있다.

둘째, 감정 평가와 통계 모형의 통합적 운용이 정확한 미술품 가격 평가를 위한 하나의 방법이 될 수 있음을 수치 결과를 토대로 확인하였다. 2장에서 살펴본 바와 같이 인간의 감정 평가는 편향될 위험이 있다. 분석 결과, 편향에 강건한 통계 모형에 감정 추정가를 반영할 때 미술품 가격을 보다 정확히 예측할 수 있었다. 어느 한 가지 방법의 우수성만을 입증하는 것을 넘어서, 감정 평가와 모형을 결합한 통합적 평가 방식의 효과성을 수치 결과로서 확인하였다는 점에서 본 연구의 의의를 찾을 수 있다. 이러한 통합적 평가 방식은 반복 작업을 최소화하여 평가자의 부담을 줄이고 전문가의 추정 가격에 객관성을 높일 수 있을 것이다.

셋째, 기존에 주로 분석되는 오프라인 시장과 함께, 최근 빠르게 규모가 증가되고 있는 온라인 시장을 분석 대상으로 하였다. 일반 대중들의 미술품 수요가 늘어나면서 온라인 미술 시장은 빠르게 증대되고 있으나 미술 시장에 관한 여러 연구들은 오프라인 시장에 초점을 맞춰왔다. 본 연구는 온라인 시장에서 예측 모형의 활용 가능성을 입증한 초기 연구라는 점에서 의의를 가진다.

넷째, 작품을 만든 작가의 특성이 미술품 가격 평가의 결정적인 예측 변수라는 사실을 발견하였다. 그동안의 많은 연구들은 헤도닉 변수의 유의성을 토대로 작품 가격에 대한 작가 특성 요인의 영향력을 규명해왔다. 다만 선형 회귀에 기반한 헤도닉 모형은 현실에 대해 엄격한 가정을 요구하며 변수 간의 상관관계에 따라 회귀 계수의 변동이 크므로 해석에 주의해야 한다. 또한 회귀 계수는 독립 변수 값의 변화에 따른 종속 변수의 변화율을 추정하므로 예측 문제에 관한 해당 변수의 영향력을 한계적으로 파악

할 수 있다. 본 연구는 랜덤 포레스트의 변수 중요도 추정 결과를 토대로 작가의 신상과 과거 거래 가격 정보가 가격 예측에 있어 중요한 예측 변수임을 확인하였다. 이 점은 선행 연구(Aubry et al., 2019; Ayub, Orban, and Mukund, 2017)가 미술품의 시각적 변수의 역할에 대해 분석하였던 점에서 차별점을 가지며 향후 미술품 가격 모델링의 개발에 기여할 수 있을 것이다.

본 연구는 전체 미술 시장에서 일부 경매회사의 데이터만을 사용했다는 한계를 가진다. 현실에는 수많은 경매사들이 존재하며 미술품은 경매 뿐 아니라 화랑과 아트 페어를 포함한 여러 시장에서 거래된다. 판매자마다 판매 대상과 전략은 다르기 때문에 시장 특성에 따라 모형의 예측 결과는 다르게 나타날 수 있다. 특히 본 연구는 경매사 추정가가 감정 평가를 대표한다고 가정하였다. 선행 연구에서 살펴본 바와 같이, 경매사의 감정 추정가는 판매를 위해 공개되기 때문에 진실된 감정 가격으로 전제하기 어렵다. 만일 추정가가 어떤 이유에서든 편향되어 작품의 시장 가치를 대표할 수 없다면, 본 연구의 통계 모형이 감정 평가에 준하거나 우수하다고 일반화할 수 없다. 무엇보다 예술품의 가치는 해당 작품이 가지는 예술적, 역사적 가치와 보존 상태, 거래 기록 등을 반영하여 면밀히 평가되어야 한다. 따라서 본 연구의 결과는 미술품 가격 평가 기법에 대한 정량적 분석 결과일 뿐, 예측 결과가 작품의 가치를 결정한다는 의미는 아니다.

본 연구에서 나아가 미래의 연구자는 다양한 평가 방법을 이용하여 미술 시장의 평가 체계를 분석할 수 있다. 이미지 변수를 사용하는 딥러닝 기술이나 보다 정밀하게 설계된 앙상블 모형은 시계열 분석을 비롯한 다양한 회귀 문제를 해결하기 위해 많이 사용되고 있다. 이러한 모형들을 적절히 응용할 수 있

다면 본 연구보다 정밀하고 효과적인 평가 모형을 개발할 수 있을 것이다. 마찬가지로 본 분석에 사용된 데이터가 대부분 5년 내외의 단기 데이터인 만큼 오랜 시간 누적된 미술 시장 데이터를 활용할 수 있다면 모형의 일반화 성능을 향상시킬 수 있을 것이다. 이러한 후행 연구가 공정하고 지속가능한 미술 시장을 구축하는 데 기여하기를 기대한다.

## 참고문헌

- Anderson, R. C.(1974), "Paintings as an Investment," *Economic Inquiry*, 12(1), pp.13-26
- Artsy (2019), "The Online Art Collector Report 2019."
- Ashenfelter, O., K. Graddy, and M. Stevens. (2002), "A Study of Sale Rates and Prices in Impressionist and Contemporary Art Auctions," *Princeton University and University of Oxford*.
- Aubry, M., R. Kraeussl, G. Manso, and C. Spaenjers. (2019), "Machines and Masterpieces: Predicting Prices in the Art Auction Market," SSRN, <https://doi.org/10.2139/ssrn.3347175>
- Ayub, R., C. Orban, and V. Mukund. (2017), "Art Appraisal using Convolutional Neural Networks."
- Bailey, J.(2020), "Can Machine Learning Predict the Price of Art at Auction?" *Harvard Data Science Review*, 2(2).
- Bauwens, L. and V. Ginsburgh.(2000), "Art Experts and Auctions: Are Pre-Sale Estimates Unbiased and Fully Informative?" *Recherches Economiques De Louvain/Louvain Economic Review*, 66(2), pp.131-144.



- Beggs, A. and K. Graddy.(1997), "Declining Values and the Afternoon Effect: Evidence from Art Auctions," *The Rand Journal of Economics*, 28(3), pp.544-565.
- Beggs, A. and K. Graddy.(2009), "Anchoring Effects: Evidence from Art Auctions," *American Economic Review*, 99(3), pp.1027-1039.
- Breiman, L.(1996), "Bagging Predictors," *Machine Learning*, 24(2), pp.123-140.
- Breiman, L.(2001), "Random Forests," *Machine Learning*, 45(1), pp.5-32.
- Chen, T. and C. Guestrin.(2016), "Xgboost: A Scalable Tree Boosting System," *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp.785-794.
- Choudhry, R. and K. Garg.(2008), "A Hybrid Machine Learning System for Stock Market Forecasting," *World Academy of Science, Engineering and Technology*, 39(3), pp.315-318.
- Fedderke, J. W. and K. Li.(2020), "Art in Africa: Hedonic Price Analysis of the South African Fine Art Auction Market, 2009-2014," *Economic Modelling*, 84, pp.88-101.
- Friedman, J. H.(2001), "Greedy Function Approximation: A Gradient Boosting Machine," *Annals of Statistics*, 29(5), pp.1189-1232.
- Garay, U.(2021), "Determinants of Art Prices and Performance by Movements: Long-Run Evidence from an Emerging Market," *Journal of Business Research*, 127, pp.413-426
- Grömping, U.(2009), "Variable Importance Assessment in Regression: Linear Regression Versus Random Forest," *The American Statistician*, 63(4), pp.308-319.
- Higgs, H. and A. Worthington.(2005), "Financial Returns and Price Determinants in the Australian Art Market, 1973-2003," *Economic Record*, 81(253), pp.113-123.
- Huh, B. G. and Y. K. Jung.(2013), "The Effects of Data Mining Ensemble Techniques on Audit Risk Reduction," *Korean Management Review*, 42(5), pp.1523-1559.
- James, G., D. Witten, T. Hastie, and R. Tibshirani.(2013), "An Introduction to Statistical Learning," Vol. 112, Springer.
- Jang, D. R. and M. J. Park.(2019), "Price Determinant Factors of Artworks and Prediction Model Based on Machine Learning," *Journal of Korean Society for Quality Management*, 47(4), pp.687-700.
- Jang, D. R. and M. J. Park.(2020a), "A Study on the Art Price Prediction Model using the Random Forest," *Journal of Applied Reliability*, 20(1), pp.34-42.
- Jang, D. R. and M. J. Park.(2020b), "Financial Returns and Price Determinants of Art: A Hedonic Quantile Regression Approach," *Journal of Applied Reliability*, 20(2), pp.133-144.
- Kim, T. H., M. S. Kim, H. D. Shin, and Y. S. Kim.(2016), "Study on the Art Price Index Including Non-Auction Market in Korea," *The Journal of Cultural Policy*, 30(1), pp.32-54.
- Korea Arts Management Service(2019), "Survey on the Art Market."
- Lee, C. R. and K. H. Park.(2016), "Application of Machine Learning Models for Estimating House Price," *Journal of the Korean Geographical Society*, 51(2), pp.219-233.
- Lee, D. K.(2019), "Study on Art Authentication and Appraisal Policy in Visual Arts Administration," *Journal of Governance Studies*,

- 14(1), pp.83-103.
- McAndrew, Clare(2019), *The Art Basel and UBS Global Art Market Report* Art Basel and UBS, Art Basel and UBS
- McAndrew, C. and R. Thompson.(2007), "The Collateral Value of Fine Art," *Journal of Banking & Finance* , 31(3), pp.589-607.
- Mei, J. and M. Moses.(2005a), "Beautiful Asset: Art as Investment," *Journal of Investment Consulting* , 7(2), pp.45-51.
- Mei, J. and M. Moses.(2005b), "Vested Interest and Biased Price Estimates: Evidence from an Auction Market," *The Journal of Finance*, 60(5), pp.2409-2435.
- Ministry of Culture, Sports and Tourism, (2018), "Mid & Long Term Plan for Promotion of Visual Arts."
- Nahm, J. W.(2011), "Price Determinants and Financial Returns in Korean Art Investment," *The Korean Journal of Economic Studies*, 59(1), pp.5-24.
- Park, B. H. and J. K. Bae.(2015), "Using Machine Learning Algorithms for Housing Price Prediction: The Case of Fairfax County, Virginia Housing Data," *Expert Systems with Applications*, 42(6), pp.2928-2934.
- Park, J. H. and H. D. Shin.(2012), "Would Online Artwork Auction be Better than Offline? Focusing on the Impacts of Price Determinants on the Fetching Price," *Korean Management Review*, 41(4), pp.789-808.
- Patel, J., S. Shah, P. Thakkar, and K. Kotecha. (2015), "Predicting Stock and Stock Price Index Movement using Trend Deterministic Data Preparation and Machine Learning Techniques," *Expert Systems with Applications*, 42(1), pp.259-268.
- Shen, S., H. Jiang, and T. Zhang.(2012), "Stock Market Forecasting using Machine Learning Algorithms," *Department of Electrical Engineering, Stanford University, Stanford, CA* pp.1-5.
- Sproule, R. and C. Valsan.(2006), "Hedonic Models and Pre-Auction Estimates: Abstract Art Revisited," *Economics Bulletin*, 26(5), pp. 1-10.
- Taylor, D. and L. Coleman.(2011), "Price Determinants of Aboriginal Art, and its Role as an Alternative Asset Class," *Journal of Banking & Finance*, 35(6), pp.1519-1529.
- Worthington, A. C. and H. Higgs.(2006), "A Note on Financial Risk, Return and Asset Pricing in Australian Modern and Contemporary Art," *Journal of Cultural Economics*, 30(1), pp.73-84.
- Yu, L., W. Dai, and L. Tang.(2016), "A Novel Decomposition Ensemble Model with Extended Extreme Learning Machine for Crude Oil Price Forecasting," *Engineering Applications of Artificial Intelligence*, 47, pp.110-121.

- 
- The author Dongryul Jang graduated from Hongik University with a master's degree in Arts and Cultural Management. His main interests are machine learning, big data modeling, and cultural industry. His paper related was selected as outstanding paper award in 'the 18th Statistics Korea Research Competition'.
  - The author Minjae Park is currently an associate professor at Business School, Hongik University, Seoul, Korea. His research interests include quality management, reliability modeling, maintenance policy, mean shift detection, optimization, and applied statistics.