

머신러닝을 이용한 관중 수요 예측에 관한 연구

Study on Prediction of Attendance Using Machine Learning

유 지 현*

Ji-Hyun Yoo*

Abstract

People who gathered to enjoy a specific event or content are called audiences or spectators, and show various propensity according to the characteristics of the crowd. Although there is such a difference, in general, the number of attendance is directly related to the business aspect, which enables stable financial operation for the sale of contents through various incomes, such as the admission fee and the use of other facilities. Therefore, prediction of audience can be used as a major factor in marketing and budgeting strategies. In this study, we review several existing models for predicting the number of attendance and propose an efficient machine learning model. In addition, we studied daily attendance prediction and abnormal attendance prediction using combine DNN(Deep Neural Network) and RF(Random Forest) model.

요 약

특정한 이벤트나 콘텐츠를 즐기기 위해 모인 사람들을 관중 또는 관객이라고 하고, 모임의 특성에 따라 다양한 성향을 나타낸다. 그러한 차이점은 있지만, 일반적으로 관중 수는 경영적인 측면과 직결되는 요소로써, 관람료부터 다른 시설의 이용료 등 다양한 수입을 통해 콘텐츠 판매를 위한 안정적인 재정 운영을 가능케 한다. 따라서 관중 수에 대한 예측은 마케팅과 예산 전략 수립에 주요한 요소로 활용될 수 있다. 본 연구에서는 관중 수에 대한 예측을 위한 여러 가지 기존 모델을 검토하고, 그 중에서 효율적인 머신러닝 모델을 제안하고자 한다. 또한 딥러닝과 랜덤포레스트 모델을 혼용하여 일별 관중 수 예측과 비정상적 관중 수 예측에 대한 연구를 진행하였다.

Key words : 수요예측, 머신러닝, 딥러닝, 랜덤포레스트

1. 서론

특정한 운동 경기, 공연, 영화, 전시회 등과 관련된 콘텐츠를 즐기기 위해 모인 사람들을 관중 또는 관객이라고 한다. 스포츠 경기장을 찾은 관중(Spectators)은 영화나 연극 등을 관람하는 공연 관객(Audiences)과 차이점이 있다. 어원상의 차이점

을 살펴보면 관중은 “눈으로 사건을 보려는 고객”이며 공연 관객은 “귀로 들으려는 고객”을 의미한다[1]. 다시 말하면 스포츠 관중은 어떤 사건(Event)을 볼 수 있다는 기대로 경기장을 찾는 고객을 의미한다. 하지만 음악 공연의 경우 관객들은 이미 어떤 곡이 연주될지를 어느 정도 아는 상태에서 공연장을 찾게 된다. 스포츠의 관중은 예상치

* Dept. of Internet Communications, Jangan University

★ Corresponding author

E-mail : jihyun_yoo@jangan.ac.kr, Tel : +82-31-299-3024

※ Acknowledgment

This work was supported by Jangan University Research Grant in 2018.

Manuscript received Dec. 6, 2019; revised Dec. 23, 2019; accepted Dec. 26, 2019.

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

못한 새로운 사건이 일어날 것을 기대하고 경기장에 관람하러 오게 되는 것이다.

그러한 의미에서 스포츠의 관중과 영화(엔터테인먼트)의 관객은 어느 정도 통하는 점이 있다. 영화를 보러 오는 사람 중에는 이미 내용을 거의 다 알고 있는 경우도 있겠지만 사전에 예측 못한 극적인 반전 등을 기대하고 오는 경우도 많다. 영화와 스포츠가 판매하는 제품은 무형이며, 브랜드(구단, 제작사, 감독)에 대한 지지가 높고, 핵심 판매상품(경기, 영화)과 보조 상품(식음료, 기념품 등)이 존재하며, 가격의 설정이 중요하고, 정해진 시간이 지나면 다시 구매할 수 없으며, 광고가 제품에 부착되기도 하고, 다양한 관람 플랫폼이 존재하며, 실패 가능성이 높은 비즈니스라는 측면에서 공통점이 있다. 하지만 스포츠는 팬들의 충성도가 매우 높은 편이며 관람 수익 외에 스폰서 수익도 주요한 요인이라는 점에서 영화와 차이점이 있다.

관중 수는 경영적인 측면에서 매우 중요한 요소로써, 이를 기본으로 콘텐츠에 대한 관람료와 다른 시설의 이용료 등 다양한 수입을 창출할 수 있다. 따라서 관중 수에 대한 예측은 마케팅과 예산 전략 수립에 기본적인 요소로 활용된다. 본 연구에서는 관중 수에 대한 예측을 위해 효율적인 머신러닝 모델을 제안하고, 관련 기업의 마케팅 자료로써의 효용성을 증대시키기 위해 일별 관중 수 예측과 비정상적 관중 수 예측에 대한 연구를 진행하였다.

II. 본론

1. 예측 방법론

예측 방법론에서 사용하는 데이터는 사전에 수집된 과거 데이터나 제한된 데이터를 대상으로 하므로 예기치 않은 사회적 이슈와 미세먼지와 같이 새롭게 주목을 받는 요인들은 체계적으로 수집되어 있지 않은 경우가 많다. 이런 한정적인 데이터를 이용한 예측은 각 데이터의 영향력이 과대평가될 수 있으므로 미래의 예측값의 오차를 크게 할 수 있다. 연속적이거나 이산되어 있는 입력데이터들의 차이도 적절한 결과를 예측하기에 문제가 될 수 있다.

이러한 예측 방법론이 가진 오차와 한계에도 불구하고 예측의 긍정적인 효용성 때문에 최근 등장하고 있는 빅데이터 기반의 머신러닝 등의 방법론을 통한 노력이 꾸준히 진행되고 있다.

가. 선형회귀분석

선형회귀분석은 벡터 독립변수 x 와 스칼라 종속변수 y 의 관계를 정량적으로 분석하여 가장 비슷한 예측값 \hat{y} 을 도출하는 방법론이다.

$$\hat{y} = f(x) \approx y$$

선형회귀분석을 위해서는 각 변수의 존재를 사전에 파악할 필요가 있다. 관중수 예측에서 선형 회귀 분석(다중회귀분석)을 사용할 경우, 관중수에 영향을 미치는 변수를 어느 정도 알 수 있어야 하므로 예측 결과값이 총관중수와 같은 평균값 도출에는 적합하지만, 구역별 관중수 등을 세밀하게 예측값을 도출해야 할 경우에는 입력 변수 및 데이터의 한계로 결과값에 오차가 커질 수 있다.

나. 시계열분석

시계열분석 방법은 양적 예측방법으로 과거의 데이터를 시간에 따른 변화를 파악하여 예측값을 도출하는 방법론이다. 시계열 분석방법에는 지수평활법, 자기회귀법, ARIMA법이 있다. 지수평활법은 과거 데이터 영향력의 차이를 줄이기 최신 자료에 가중치를 주어서 예측값을 도출하는 방법이다. 자기회귀법은 과거 데이터가 미치는 영향력을 어느 정도 제거하여 예측값을 도출하는 방법이다. ARIMA법은 시계열 분석 방법의 대표적인 방법으로써, 시계열 자료의 자기 상관 특성을 이용한다. 이와 같은 다양한 시계열분석 방법론을 이용한 예측은 통상 오랜 기간의 데이터가 있을 때 사용한다[2].

시계열 분석(지수평활, 자기회귀, ARIMA) 방법론을 관중수 예측에 활용하려면 오랜 기간의 관중수 데이터가 있어야 한다. 새로운 이벤트의 경우 누적 데이터가 부족하기 때문에 원하는 관중수 예측값을 도출하는 데는 한계가 있을 수 밖에 없다.

다. 시뮬레이션

시뮬레이션(수학적 모델링) 기법은 기업의 비즈니스 로직을 수학적으로 구축하여 컴퓨터 시뮬레이션을 통해 예측값을 도출하는 방법이다. 보통 물류, 유통 등 비즈니스 로직을 세세히 잘 알고 있을 때 사용한다. 시뮬레이션 기법은 최적의 우편물 배달 경로 도출과 같이 통계적이거나 수학적인 분석으로는 정확한 예측 값을 주어진 시간 내에 도출할 수 없을 때 주로 사용한다.

시뮬레이션(수학적 모델링) 기법은 관중수에 영향을 미치는 비즈니스 로직을 정확히 파악하고 있을 때 사용할 수 있다. 아직 프로야구 관중수에 영향을 미치는 요인에 대한 연구나 세밀한 비즈니스 로직을 분석한 결과가 많지 않아서 관중수 예측에 적용하기는 쉽지 않을 것이다.

라. 머신러닝

머신러닝이란 주로 빅데이터를 활용해 비선형의 형태로 결과값을 예측하는 방법이다. 머신러닝 기법은 선형회귀분석 방법론과 달리 사전에 영향을 미치는 변수를 모두 알지 못한 상태에서도 예측값을 도출할 수 있다. 따라서 빅데이터 형태로 자료를 수집할 수 있고, 예측하지 못한 변수들이 종종 등장하는 경우에 적절히 활용할 수 있다. 다만 실제 분석시간보다 데이터를 컴퓨터가 이해하기 쉽도록 정제하는 시간이 더 많이 걸릴 수가 있고, 분석방법론에 따라 예측값이 달라지는 한계도 존재한다.

머신러닝 방법론은 빅데이터를 활용해 비선형의 형태로 관중수를 예측할 때 사용할 수 있다. 또한 예측 못한 변수가 있더라도 데이터의 학습을 통하여 어느 정도 예측값을 도출하는 것이 가능하다. 따라서 현재의 제한된 기간에 수집된 빅데이터를 활용하여 예측값을 도출하기에 최적의 방법론으로 볼 수 있다.

2. 연구방법 및 분석

가. 자료수집 및 모델설계

본 연구에서는 다양한 형태의 관중과 관객 중에서 한국프로야구의 관중을 선택하였고, 관중 수 및 야구경기 관련 데이터들은 KBO에서 제공하는 2015년부터 2018년 연감에 수록된 공식 데이터를 사용하였으며 부족한 데이터는 kt wiz 홈페이지와 관계사를 통해 수집하였다. 2015년에서 2017년의 kt wiz의 예매 데이터를 활용하여 학습을 수행하였다. 학습 데이터는 이 기간의 216 경기(72 경기 * 3년) 데이터를 이용하였다. 학습 결과를 바탕으로 2018년 경기 예매데이터를 이용하여 테스트를 수행하였고, 2018년 72경기의 예매 관중 패턴을 예측하여 실제값과 비교하였다.

무수한 머신러닝 방법론 중에 본 논문에서는 DNN(Deep Neural Network)과 RF(Random Forest)를

고려하였다.

(1) Deep Neural Network

딥러닝 기법은 선형회귀기법 등과 달리 사전 학습 없이 무작위로 데이터를 입력한 뒤 컴퓨터의 판단에 의존하여 유의미한 패턴을 추출하는 방법이다.

인공 신경망은 그림1과 같이 노드들의 그룹으로 연결되어 있다. 각 원 모양의 노드는 입력층(Input layer), 은닉층(Hidden layer)이라 부르는 하나 이상의 TLU(Threshold Logic Unit)층과 마지막으로 출력층(Output layer)으로 구성된다. 인공 신경망의 은닉층이 2개 이상일 때, 심층 신경망(DNN, Deep Neural Network)이라고 한다. 각 노드들의 정보는 각각 고유한 가중치(weight)를 곱하여 다음 층의 모든 노드로 전달된다. 다음 층의 입력값은 이전의 모든 노드와 가중치들을 곱의 합을 처리해주는 활성화 함수(Activation function)를 거쳐 다음 층으로 다시 연결된다.

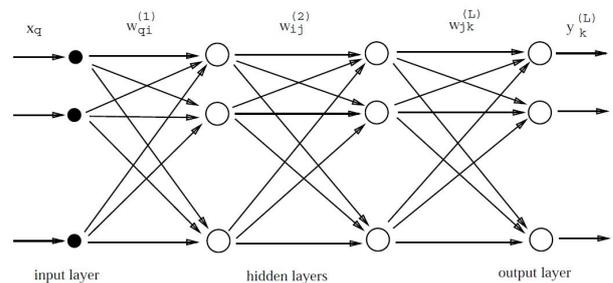


Fig. 1. Structure of Artificial Neural Network.

그림 1. 인공 신경망 구조

활성화 함수의 종류로는 시그모이드(Sigmoid) 함수, tanh(Tangent Hyperbolic) 함수, ReLU(Rectified Linear Unit) 함수 등이 있다. tanh 함수는 시그모이드 함수의 문제점인 훈련이 지연되는 점을 해결할 수 있고, ReLU 함수는 더 빠르게 수렴하고, 그라디언트가 소실되는 것을 막을 수 있다[4]. 본 연구에서는 은닉층의 활성화 함수로 시그모이드 함수를 선정하였다.

프로야구 경기의 관중수 예측에 딥러닝을 활용하는 과정에서 표1은 위에서 언급한 인공신경망의 입력 변수와 출력변수로 사용한 요소들이다. 은닉층과 은닉 노드의 개수는 표 2와 같이 설정해주었고, 실제값과 출력값과의 오차를 오류역전파(Backpropagation) 알고리즘으로 보정하였다.

Table 1. Input and Output Variables.

표 1. 입력변수와 출력변수

Variables	Parameters	
Input	Time	Date, Day, Holiday, Peak
	Climate	Temperature
	Other team	Opponents Team
	Last match result	Win, Lose
Output	Attendance per game	

Table 2. Hyperparameters.

표 2. 하이퍼파라미터

Hyperparameters		Range
Input node		4
Output node		4
The number of nodes for hidden layers	1 layer	10 cases
	2 layer	10 cases
Activation function for hidden layer		Logistic Sigmoid
Activation function for output layer		Tangent Sigmoid
Stopping metric		RMSE

(2) Random Forest

RF분석 기법은 우선 변수 개수를 무작위(Random)로 적용하여 의사 결정 트리(Decision Tree)를 다수 만들고 숲(forest)을 구성한다. 본 연구에서 kt wiz 관중예측에 사용한 변수는 4가지로 날짜, 상대팀, 요일, 공휴일 유무인데, 원하는 결과값이 나올 때까지 반복적으로 결정트리를 만들고 학습을 수행하고 결과를 피드백하였다. kt wiz의 데이터는 상대팀과 요일을 구분하면 4년치라고 하여도 데이터가 적어서 학습 시간은 많이 걸리지 않았지만, 데이터의 영향력을 과도하게 해석하는 오버피팅(overfitting)이 발생하여 예측값에 오차가 생기기도 하였다. 그러므로 딥러닝과 비교하여 RF가 더 좋은 예측 결과가 나올 경우 사용할 필요가 있었다.

나. 결과 분석

딥러닝(Deep Learning)은 사전에 인간에 의한 작업이 없으므로 컴퓨터가 스스로 분석하기 위한 많은 시스템 리소스가 필요하고 연산 속도 매우 느리다. 그러므로 일반적인 머신러닝과 상호 보완적으로 사용할 필요가 있다. 관중수 데이터를 활용하여 예측값을 도출한 결과 딥러닝은 경기별 총관중수의 예측에 정확도가 높은 것으로 나타났고, RF는

구역별 좌석점유 예측에 더 높은 정확도를 보여주었다.

RF(Random Forest) 기법을 이용한 관중수 예측 분석 절차는 다음과 같다. 2015년에서 2017년까지의 kt wiz의 예매 데이터를 활용하여 학습을 수행하였고, 학습 결과를 바탕으로 2018년 경기 예매 관중 패턴을 예측하여 실제값과 비교하였다. 예측 결과 72경기 중 67 경기에서 유효한 예측 데이터가 생성되었다. 나머지 5경기는 데이터 오류가 발생하여 제외하였다. 이 분석은 월별, 주중, 주말별로 구별하여 예측하였는데 추가 보정 필요한 것으로 나타났다. 학습데이터를 기반으로 한 2018년 총 관중 예측 결과는 72만 명으로 나타났는데 실제 관중수는 64만 명이어서 오차는 13% 수준이었다.

관중수가 비정상적으로 낮게 나타나는 경우를 비정상 사례(Abnormal Case)로 정의하여 파악해 보았다. AC1은 특정 경기일의 예측 관중수가 평균 관중(월, 주중, 주말) 대비 25% 이하로 낮게 예측될 때 발생하는 비상상황으로 정의하였다. 예측결과 2018년에 AC1 횟수는 총 12회로 나타났다. 즉, 주말에는 22, 36, 51번째 경기의 3회가 관중이 낮을 것으로 예측되었고, 주중에는 7, 17, 23, 33, 41, 55, 56, 57, 67회 경기의 관중이 낮게 예측되었다.

Table 3. Comparison of AC1 Prediction and Actual Attendance.

표 3. AC1 예측 결과와 실제 관중수 비교

Round	Date	Day	Other Team	Prediction	Base AC1	Actual	Comment
7	20180418	Wed	SK	3,380	4,829	4,010	
17	20180508	Tue	Samsung	3,971	4,127	3,388	
22	20180520	Sun	NC	10,001	10,305	9,162	Weekend
23	20180625	Fri	LG	4,061	5,885	9,634	More than prediction
33	20180620	Wed	Lotte	5,295	5,885	6,068	
36	20180623	Sat	SK	9,122	10,774	9,343	Weekend
41	20180705	Thu	Samsung	4,590	4,787	2,879	
51	20180804	Sat	Nexen	7,400	7,800	6,747	Weekend
55	20180814	Tue	NC	4,110	4,136	4,044	
56	20180815	Wed	NC	2,940	4,136	6,442	
57	20180816	Thu	NC	3,880	4,136	3,058	
67	20180926	Wed	KIA	4,982	6,642	19,692	More than prediction

AC2는 전일 대비 관중수가 15% 이상 감소할 것으로 예측될 때 발생하는 비정상 사례(Abnormal

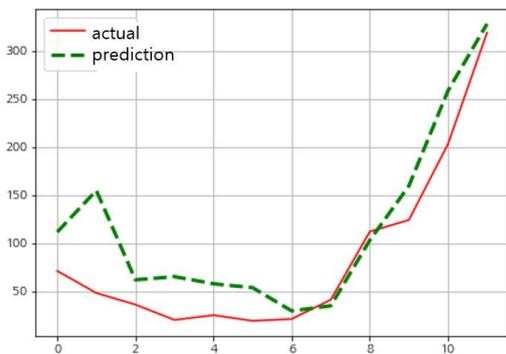
Case)로 정의하였다. 예측결과 2018년의 AC2 횟수는 총 11회로 나타났다. 주말에는 21, 25, 36번째 경기가 관중이 낮을 것으로 예측되었고, 주중에는 8, 18, 32, 33, 45, 47, 60, 61회 경기가 AC2의 수준으로 관중이 적게 올 것으로 예측되었다.

AC2 예측 결과를 실제 데이터와 비교해본 결과 11회의 모든 AC2 상황에서 실제로 관중수가 전날보다 크게 감소할 것으로 나타나서 유의미한 예측을 하고 있는 것으로 확인되었다.

Table 4. Comparison of AC2 Prediction and Actual Attendance.
표 4. AC2 예측 결과와 실제 관중수 비교

Round	Date	Day	Other Team	EC2 Occurrence	Correction of Prediction	Actual	Average
8	20180419	Thu	SK	D-10	230 ↓	4,335	6,438
18	20180509	Wed	Samsung	D-10	550 ↓	5,664	5,502
21	20180519	Sat	NC	D-11	1,512 ↓	11,399	13,742
25	20180527	Sun	LG	D-10	1,235 ↓	15,677	13,742
32	20180619	Tue	Lotte	D-11	633 ↓	5,977	7,846
33	20180620	Wed	Lotte	D-10	751 ↓	6,068	7,846
36	20180623	Sat	SK	D-11	1,074 ↓	9,343	7,229
45	20180717	Tue	Hanhwa	D-8	1,050 ↓	9,339	6,382
47	20180719	Thu	Hanhwa	D-9	1,350 ↓	9,522	6,382
60	20180906	Thu	Hanhwa	D-10	852 ↓	6,912	8,856
61	20180907	Fri	Hanhwa	D-10	1,135 ↓	9,608	12,127

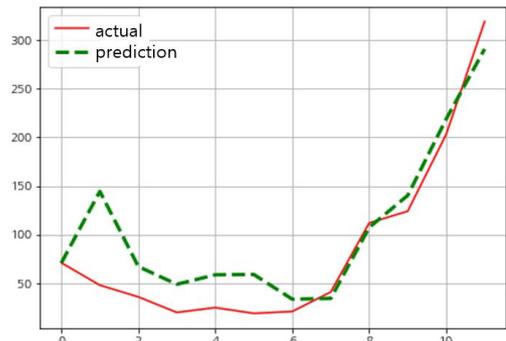
AC2 예측을 경기 전 12일 동안의 예매 패턴을 활용하여 분석해본 결과는 다음과 같다. 다음 그림에서 점선은 예측결과를 바탕으로 한 경기 전 12일 간의 예매 패턴이다. 그림 2는 12일전 예매, 그림 3은 11일전 예매, 그림 4는 10일전 예매이다.



Total Attendance(Actual=4426, Prediction=6534), RMSE:43.39

Fig. 2. Prediction of Reservation Pattern Using Random Forest(D-12).

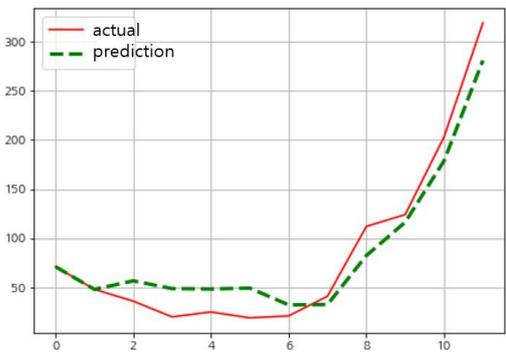
그림 2. 머신러닝을 이용한 예매패턴 예측(D-12)



Total Attendance(Actual=4426, Prediction=5419), RMSE:37.38

Fig. 3. Prediction of Reservation Pattern Using Random Forest(D-11).

그림 3. 머신러닝을 이용한 예매패턴 예측(D-11)



Total Attendance(Actual=4426, Prediction=4990), RMSE:24.29

Fig. 4. Prediction of Reservation Pattern Using Random Forest(D-10).

그림 4. 머신러닝을 이용한 예매패턴 예측(D-10)

실선은 실제로 관중들이 예매를 수행한 결과이다. 12일전 예측에서는 점선이 높은 곳에 있어서 관중수가 상대적으로 많을 것으로 예측하고 있으나, 11일전(1일차) 실제 예매값을 입력한 결과 점선이 아래쪽으로 내려오면서 관중 감소를 예상하는 것을 확인할 수 있다. 10일전(2일차) 실제 예매 데이터를 입력하였을 때도 최종 관중수는 낮게 유지되어 관중 감소를 예측하고 있다.

III. 결론

관중 예측을 위하여 일반적으로 사용하는 선형회귀 분석이 오차가 많아서 적용하기 쉽지 않았다. 이에 최근 새롭게 등장하고 있는 다양한 머신러닝 기법을 활용하여 관중수 예측을 수행한 결과 비교적 정확하고 세밀한 예측이 가능하였다.

다양한 머신러닝 기법 중 주로 사용한 것은 RF

(Random Forest)와 딥러닝(Deep Learning)이었다. 분석 결과 딥러닝은 RF에 비하여 연산시간이 10배 이상 걸리는데 비해 결과는 RF가 더 좋은 것으로 나타났다. 이에 관중예측을 위해서는 두 방법론을 상호 보완적으로 사용할 필요가 있다고 볼 수 있다.

관중수 데이터를 활용하여 예측값을 도출한 결과 딥러닝은 경기별 총관중수의 예측에 정확도가 높은 것으로 나타났고, RF는 구역별 좌석점유 예측에 더 높은 정확도를 보여주었다.

RF를 활용하여 경기일 이전 12일간의 예매 데이터를 활용하여 예측을 수행해본 결과 예매일 1~2일 데이터를 입력하면 예측 정확도가 매우 높아지는 것으로 나타났다. 따라서 예매 1~2일차에 해당 경기 관중 수가 정해지는 것으로 볼 수 있다. 그러므로 관중수를 높이기 위해서는 예매가 시작되기 전(경기일 12일 이전)에 전략을 수립하여 수행하는 것이 중요하다고 예상된다.

분석과정에서 대부분의 경우 RF에서는 변수가 너무 크게 영향을 미치는 오버피팅(overfitting) 또는 그 반대의 경우인 언더피팅(underfitting)이 나타났다. 이는 머신러닝에 필요한 학습 데이터의 양이 적은 것이 원인으로 판단하고 있다. 이에 대해서는 데이터 축적을 통해 추가적인 연구가 필요하다.

References

- [1] Richard Giulianotti, *Sport and Social Theorists*, Palgrave Macmillan, 2004.
DOI: 10.1057/9780230523180_1
- [2] George E. P. Box, Gwilym M. Jenkins, Gregory C. Reinsel, Greta M. Ljung, "Time Series Analysis: Forecasting and Control," *5th Edition*, Wiley, 2015. DOI: 10.1111/jtsa.12194
- [3] A. K. Jain, Jianchang Mao, K. M. Mohiuddin, "Artificial neural networks: a tutorial," *Journal Computer-Special issue: neural computing: companion issue to Spring 1996, IEEE Computational Science & Engineering*, vol.29, no3, pp.31-44, 1996. DOI: 10.1109/2.485891
- [4] B. Karlik and A. V. Olgac, "Performance analysis of various activation functions in generalized MLP architectures of neural networks," *International Journal of Artificial Intelligence and Expert Systems*, vol.1, no.4, pp.111-122, 2011.
- [5] Wann, D. L., Martin, J., Grieve, F. G., & Gardner, L., "Social connections at sporting events: Attendance and its positive relationship with state social psychological well-being," *North American Journal of Psychology*, vol.10, no.2, pp.229-238, 2008.
- [6] T. Hegazy, O. Moselhi, and P. Fazio, "Developing practical neural network applications using back-propagation," *Journal of Microcomputers in Civil Engineering*, Vol.9, No.2, pp.145-159, 1994.
DOI: 10.1111/j.1467-8667.1994.tb00369.x
- [7] H. Larochelle, D. Erhan, A. Courville, J. Bergstra, and Y. Bengio, "An empirical evaluation of deep architectures on problems with many factors of variation," *Proceedings of the 24th International Conference on Machine learning*, ACM, 2007. DOI: 10.1145/1273496.1273556
- [8] A. Y. Ng., "Feature selection, L1 vs. L2 regularization, and rotational invariance," *Proceedings of the 21st International Conference on Machine learning*, 2004.
- [9] R. J. Hyndman, and B. K. Anne, "Another look at measures of forecast accuracy," *International Journal of Forecasting*, Vol.22, No.4, pp.679-688, 2006. DOI: 10.1145/1015330.1015435
- [10] Tamas D. Gedeon, "Data mining of inputs: analysing magnitude and functional measures," *International Journal of Neural Systems*, Vol.8, No.2, pp.209-218, 1997.
DOI: 10.1142/s0129065797000227
- [11] J. U. Park, S. H. Park, "A Study on Prediction of Attendance in Korean Baseball League Using Artificial Neural Network," *KIPS Transactions on Software and Data Engineering*, Vol.6, No.12, pp.565-572, 2017. DOI: 10.3745/KTSDE.2017.6.12.565
- [12] "Korea Baseball Organization," <https://www.koreabaseball.com/Reference/Ebook/>
- [13] "KT Wiz," <http://www.ktwiz.co.kr/sports/site/baseball/stats/>
- [14] Fausett, L. V., *Fundamental of neural networks: architectures, algorithms, & applications*, NJ: Prentice-Hall, 1994.

[15] Haykin, S. C., *Neural networks: A comprehensive foundation*, NJ : Prentice-Hall, 1994.

BIOGRAPHY

Ji-Hyun Yoo (Member)



1995 : BS degree in Computer Science and Engineering, Hanyang University.

2000 : MS degree in Computer Science and Engineering, Hanyang University.

2012 : PhD degree in IT Service Management, Soongsil University

2014 ~ : Professor in the Department of Internet Communication, Jangan University