

# 딥러닝 기법을 활용한 가구 부자재 주문 수요예측\*

## Demand Prediction of Furniture Component Order Using Deep Learning Techniques

김재성<sup>1</sup> · 양여진<sup>1</sup> · 오민지<sup>1</sup> · 이성웅<sup>2</sup> · 권순동<sup>3</sup> · 조완섭<sup>3\*</sup>

충북대학교 대학원 빅데이터학과<sup>1</sup>, 새한<sup>2</sup>, 충북대학교 경영정보학과<sup>3</sup>

### 요약

최근 코로나 19 사태로 인한 경기 위축에도 불구하고, 재택근무 증가로 집에 거주하는 시간이 늘어나면서 주거환경에 관한 관심이 커지고 있으며, 이에 따라 리모델링에 대한 수요가 증가하고 있다. 또한, 정부의 부동산 정책 또한 규제 정책에서 주택공급 확대 방향으로 전환하면서 이에 따른 인테리어, 가구업체의 매출에도 가시적인 영향이 있을 것으로 예상된다. 정확한 수요예측은 재고 관리와 직결되는 문제로 정확한 수요예측은 불필요한 재고를 보유할 필요가 없어 과잉생산으로 인한 물류, 재고 비용을 줄여줄 수 있다. 하지만 정확한 수요를 예측하기 위해서는 지속적으로 변화하는 경제동향, 시장동향, 사회적 이슈 등 외부요인을 모두 고려하여 분석해야 하기 때문에 어려운 문제이다. 본연구에서는 가구 부자재를 생산하고 있는 제조업체에 대하여 신뢰성 있는 결과 도출을 위해 인공지능기반 시계열 분석 방법으로, LSTM 모형, 1D-CNN 모형을 비교 분석하였다.

■ 중심어 : 가구 부자재, 수요예측, 재고관리, ARIMA, LSTM, 1D-CNN

### Abstract

Despite the recent economic contraction caused by the Corona 19 incident, interest in the residential environment is growing as more people live at home due to the increase in telecommuting, thereby increasing demand for remodeling. In addition, the government's real estate policy is also expected to have a visible impact on the sales of the interior and furniture industries as it shifts from regulatory policy to the expansion of housing supply. Accurate demand forecasting is a problem directly related to inventory management, and a good demand forecast can reduce logistics and inventory costs due to overproduction by eliminating the need to have unnecessary inventory. However, it is a difficult problem to predict accurate demand because external factors such as constantly changing economic trends, market trends, and social issues must be taken into account. In this study, LSTM model and 1D-CNN model were compared and analyzed by artificial intelligence-based time series analysis method to produce reliable results for manufacturers producing furniture components.

■ Keyword : Furniture Component, Oer demand Forecast, Inventory Control, ARIMA, LSTM, 1D-CNN F

2020년 11월 30일 접수; 2020년 12월 11일 수정본 접수; 2020년 12월 21일 게재 확정.

\* 본 과제(결과물)는 교육부와 한국연구재단의 지원으로 지원을 받아 수행된 사회맞춤형 산학협력 선도대학(LINC+) 육성사업의 연구결과입니다. (1345323364)

† 교신저자 (wscho@chungbuk.ac.kr)

## I. 서론

최근 정부가 발표한 8.4 대책[1]에서 수도권 내 안정적 주택 공급기반을 마련하기 위해 공공택지 84만 호, 정비 39만 호, 기타\* 4만 호 등 127만 호 주택을 올해부터 순차 공급한다는 정책을 내놓고 있다. 또한, 코로나 19사태로 인한 경기 위축에도 불구하고, 주거환경에 관한 관심이 커지고 있으며, 리모델링에 대한 수요가 계속해서 증가하고 있다. 한샘의 올해 2분기 연결 영업이익은 전년 동기 대비 172.3% 증가하였으며 매출은 26% 가까이 상승하였다[2]. 신영증권 리서치센터에서 제공한 자료에 따르면, 인테리어 시장의 상승세는 2020년 이후에도 이어질 것으로 전망된다. 국내 리모델링 시장이 연평균 7.5%씩 고속성장해 2030년에는 현재 대비 2.5배 이상 확대될 것으로 내다보았다[3]. 이에 따른 인테리어, 가구업체의 수요변화와 매출에 영향이 있을 것으로 예상된다.

기업 측면에서 수요의 예측은 생산, 자재 및 물류 등의 계획과 관리 측면에서 중요하다. 대부분의 중소 제조 기업은 다품종 소량생산 형태로 고객의 주문을 대략 예측하여 자재를 대량 구매하고 주문에 따라 재가공하여 판매하는 형태이다. 자재 주문의 리드 타임이 비교적 길어지게 되면 고객의 니즈를 대응하기 어렵다. 고객의 니즈와 트렌드 변화에 따라 정확한 리드 타임 파악과 적절한 주문량 파악을 할 수 있는 재고관리가 이루어져야 한다. 이를 통해 현장에서 발생하는 다양한 변수를 예측하여 효율적인 재고관리가 가능하다[4].

수요 예측은 불규칙한 시계열 특성이 있으며, 정확한 수요 예측은 재고관리와 직결되는 문제로 수요 예측을 잘하면 불필요한 재고를 보유할 필요가 없어 과잉생산으로 인한 물류, 재고 비용을 줄여줄 수 있다. 하지만 정확한 수요를 예측하기 위해서는 불규칙적으로 변화하는 경제

동향, 시장 동향, 사회적 이슈 등 외부요인을 모두 고려해야 하기 때문에 어려운 문제이다. 김정아, 정종필, 이태현, 배상민(2018)은 ARIMA 모형을 이용하여 계절적 요인과 같은 시간적인 변동성을 찾아 수요를 예측하고 이를 통해 경제적 주문량 모형 기반의 수요 예측 모델을 제안했다[4].

최근 인공지능 기술의 발전으로 불규칙한 시계열 데이터에 대하여 딥러닝 알고리즘을 이용하여 시계열 데이터의 연속성을 스스로 찾아내도록 하는 방법[5, 6]이 활발하게 연구되고 있다. 김진섭, 황재성, 정재우(2020)는 시계열 분해 데이터를 이용한 LSTM 기법 기반 항공기 수리부속 수요 예측 방안 연구에서 시계열 데이터가 선형적인 특성을 보이는 Smooth 한 수요패턴에 대해서는 전통적 통계 기법도 수요 예측 정확도가 비교적 우수하지만, 수요가 불규칙한 Erratic, Lumpy 수요패턴에 대해서는 통계적 방법으로 수요를 예측하는데 제한이 있고, LSTM 기법이 우수하다는 연구결과를 보여주고 있다[7]. 또한, 많은 연구에서 전력수요 예측을 비롯하여 불규칙한 시계열 데이터 연구에서는 인공지능 딥러닝 알고리즘이 기존 ARIMA 모형보다 더 좋은 성능을 내고 있다[8, 9, 10].

인공지능 및 딥러닝 알고리즘을 사용하여 성능이 좋은 예측 모델을 구축하려는 많은 시도에도 불구하고 데이터 셋에 따라 동일한 모델과 파라미터를 적용하여도 결과가 일정하지 않을 수 있다[11]. 따라서 데이터 셋의 성격을 고려하여 예측 모델을 최적화할 필요가 있다.

또한, 2차원 데이터를 이용하는 CNN을 1차원 시계열 데이터에 활용하여 데이터 예측 분석에 적용한 연구가 있다[12, 13].

본 연구의 목표는 가구 부자재를 생산하고 있는 A 제조업체에 대하여 신뢰성 있는 결과 도출을 위해 통계적 시계열 분석방법인 ARIMA 모형과 인공지능기반 시계열 분석 방법인 단변량

LSTM 모형, 다변량 LSTM 모형, 1D-CNN 모형으로 수요 예측을 진행하고 그 성능을 비교 분석하였다.

본 논문은 다음과 같이 구성된다. 2장은 통계적인 시계열 데이터 수요 예측 방법으로 ARIMA 예측모형과 인공신경망 기반 시계열 데이터 수요 예측 모형인 LSTM, 1D-CNN 알고리즘을 비교 설명한다. 3장은 본 연구에서 수요 예측에 사용된 모형과 데이터셋에 대하여 설명하고, 예측 정확성 판단을 위해 성능평가 지표를 제시한다. 4장은 수요 예측 정확성 진단을 위한 실험을 수행한다. 5장에서 모형 성능에 대한 평가결과와 함께 결론으로 마무리 짓는다.

## II. 관련 연구

본 장에서는 통계적인 시계열 데이터 수요 예측 방법과 인공신경망 기반 시계열 데이터 수요 예측 방법을 소개하고, 인공신경망 기반 시계열 데이터 수요 예측 모형인 LSTM, 1D-CNN 알고리즘을 설명한다.

시계열 데이터를 활용하여 수요를 예측하는 방법에는 크게 통계적 분석방법과 인공신경망 기반의 머신러닝, 딥러닝 기법으로 나눌 수 있다.

통계적 분석방법으로는 시계열 자료의 추세 요인과 계절 변동요인 등을 예측에 반영하는 지수평활법(Exponential Smoothing), 계절성 요인을 고려하는 Holt Winters, 지수평활법을 수정한 Croston기법, 시계열 자료의 관심변수 또는 차분 변수가 자기 회귀 과정, 이동평균 과정과 두 과정의 결합된 과정을 따르는지를 식별하는 ARIMA (Auto Regressive Integrated Moving Average) 모형 등이 있다[7].

인공신경망 기반 시계열 데이터 수요 예측 방법에는 딥러닝을 활용한 RNN(Recurrent Neural Network)이 있다. RNN 알고리즘은 순차적인 데이터를 학습하여 classification 또는 prediction을

수행한다. 그러나 먼 과거의 상태는 현재 학습에 아무런 영향을 미치지 못하는 단점이 있다. 기본 모형의 단점을 보완하기 위해 변형된 확장 모형로 그 중 대표적인 알고리즘은 LSTM 모형이 있으며 이는, 이전상태를 오랫동안 기억하면서 순환적인 네트워크 파라미터를 자동으로 학습한다[14].

CNN(Convolutional Neural Networks)은 이미지 및 동영상 등을 분류하는 데 주로 사용되며, 특히 이차원으로 구성된 데이터에 알맞도록 설계된 다층 신경망이다[15]. 그러나 원본 데이터 위에서 움직이는 방향에 한 방향인 1D-CNN을 적용하면 시계열 예측에 활용할 수 있다.

### 2.1 ARIMA 예측 모형

ARIMA(Auto-regressive integrated moving average, 자기 회귀 누적 이동평균) 모형은 AR (Auto-regressive process, 자기 회귀)과정과 MA (Moving Average process, 이동평균) 과정을 혼합한 모형으로, 차분(differencing) 절차를 통해 정상화한 후 분석 및 예측을 수행한다. 과거의 데이터와 그 데이터가 지나는 추세를 반영하여 시계열 예측을 수행한다는 점에서 기존의 시계열 분석 방법과 차이가 있다.

$$\hat{y}_t = \mu + \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} - \beta_1 \epsilon_{t-1} - \dots - \beta_p \epsilon_{t-p}$$

<수식 1> ARIMA 모형의 일반식

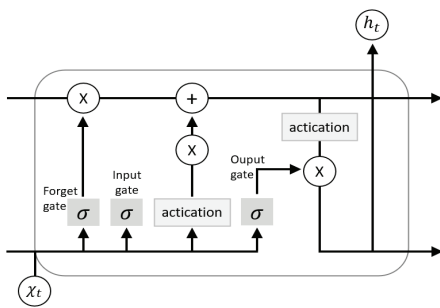
$$\begin{aligned} \phi_p(B)\Phi_p(B)W_t &= \theta_q(B)\Theta_Q(B)\epsilon_t, \\ \phi_p(B) &= 1 - \phi_1 B - \dots - \phi_p B^p, \\ \Phi_p(B) &= 1 - \phi_1 B^s - \dots - \phi_p B^{Ps}, \\ \theta_q(B) &= 1 - \theta_1 B - \dots - \theta_q B^q, \\ \Theta_Q(B) &= 1 - \theta_1 B^s - \dots - \theta_Q B^{Qs}, \\ W_t &= \nabla^d \nabla_s^d Z_t \end{aligned}$$

<수식 2> SARIMA 모형의 일반식

이러한 ARIMA 모형에 주기적 특성이나 계절성을 반영한 것이 SARIMA(Seasonal Auto-regressive integrated moving average) 모형이다. 예측하고자 하는 시점에서 가까운 과거의 자료들만을 이용하는 ARIMA 모형과 달리, 이전 주기의 자료를 추가로 활용한다[9].

### 2.2 LSTM 예측 모델

LSTM(Long Short Trem Memory) 순환 신경망은 Hochreiter&Schmidhuber이 제안한 모델로 RNN의 장기 의존성 문제를 해결하기 위해 고안되었다[14]. LSTM은 RNN에서 각 셀이 3개의 게이트를 가지도록 한 모델로, RNN 모델에 cell-state를 추가하여 state가 오래 경과하더라도 가중치의 전파가 비교적 잘 일어나도록 한 것이다. <그림 1>은 LSTM에서 각 셀이 가지는 구조를 도형으로 나타낸 것이다. <그림 1>에서 forget gate( $f_t$ )는 어떤 정보를 버릴지에 대한 계산을 수행하고 input gate( $i_t$ )는 새로 들어올 데이터 중 어떤 것을 cell-state에 저장할지 결정한다. output gate( $o_t$ )는 출력 값을 결정한다[16].




<그림 1> LSTM cell의 구조

### 2.3 1D-CNN 예측 모델

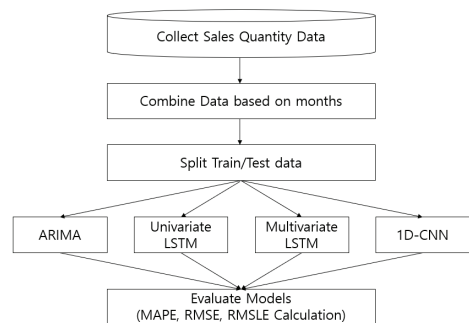
CNN(Convolutional Neural Network, 합성곱 신경망)은 딥러닝 알고리즘의 한 종류로, 격자 형태로 배열된 데이터를 처리하는 것에 특화된

어 데이터의 패턴을 식별하는 데 효과적인 신경망이다[17]. CNN의 필터(feature detector)가 원본 데이터 위에서 움직이는 과정을 convolution이라 하며, 필터가 움직이는 방향에 한 방향인 CNN을 1D-CNN이라 한다. 1D-CNN은 전체 데이터 중 길이가 고정된 짧은 구간에 대해 패턴을 인식하는 경우에 효과적이다. <그림 2>는 1D-CNN의 구조도이다. Convolution layer에서 입력된 시계열 데이터와 인접한 데이터를 필터링한 후 convolution layer의 output feature map을 형성한다. Pooling layer에서 feature의 차원축소를 위해 특징을 잘 설명하는 고정 벡터를 선별하여 시계열 데이터에서 중요한 특징을 추출한다[18].



<그림 2> 1D-CNN 의 구조

## III. 수요 예측 모델 구성



<그림 3> 수요 예측 모델 시스템 구성도

본 연구는 가구 부자재 주문 수요 예측 모델을 구축하기 위해 <그림 3>과 같이 통계적 기법

의 예측 모델인 ARIMA 모델과 인공지능기반의 예측 모델인 단변량 LSTM, 다변량 LSTM, 1D-CNN을 구축한 뒤 각각의 예측모형에 대해 세 가지 성능평가 지표로 정확성을 평가한다.

### 3.1 데이터 셋

본 연구에서는 A사의 2016년도~2020년 6월까지의 과거 4년간 제품군별 판매 수량 데이터를 사용하였다. 제품의 판매 수량은 월 단위로 집계했을 때 각 제품의 판매 수량이 연간의 추세를 가지는 것이 확인되어 예측 모델에서는 제품군 B에 대한 월별 판매 수량의 합계를 사용하였다. 데이터의 예시는 <표 1>과 같다.

<표 1> 연구 데이터 셋

Month	Sales Quantity
2016-01	31,881,560
2016-02	32,565,720
2016-03	31,670,400
...	...
2019-04	34,634,800
2019-05	35,204,500
2019-06	38,930,000

### 3.2 성능평가 지표

예측 모델의 정확도를 평가하기 위해 본 논문은 성능평가 지표로서 MAPE(Mean Absolute Percentate Error)와 RMSE(Root Mean Squared Error), RMSLE(Root Mean Square Logarithmic Error)를 사용하였으며 각 예측 모델에 대해 계산하였다.

#### 3.2.1 MAPE

MAPE(Mean Absolute Percentage Error)는 실제값에 대한 오차의 비율을 모두 합한 다음 기간 수로 나눈 값이므로 기간에 따른 값들의

크기가 크기 달라질 때 유용한 예측 오차 측정 방법이다.

$$MAPE = \frac{\sum_{t=1}^T \frac{|y_t - \hat{y}_t|}{y_t} \times 100\%}{T}$$

<수식 3> MAPE

#### 3.2.2 RMSE

RMSE(Root Mean Squared Error)는 실제값과 예측값 차이의 제곱 합을 기간 수로 나눈 뒤 제곱근을 한 값으로 양의 오차와 음의 오차가 상쇄되지 않는다는 장점이 있는 성능평가 지표이다.

$$RMSE = \sqrt{\frac{\sum_{t=1}^T (y_t - \hat{y}_t)^2}{T}}$$

<수식 4> RMSE

#### 3.2.3 RMSLE

RMSLE(Root Mean Squared Logarithm Error)는 실제값과 예측값의 차이를 제곱해 평균한 것에 루트를 씌운 RMSE에 로그를 적용한 지표이다. RMSLE는 아웃라이어에 강하고 예측값과 실제값의 상대적 오차를 측정해준다.

$$RMSLE = \sqrt{\frac{1}{T} \sum_{t=1}^T (\log(y_t + 1) - \log(\hat{y}_t + 1))^2}$$

<수식 5> RMSLE

## IV. 실험 및 결과

본 논문은 통계적 기법의 시계열 예측 모델과 인공지능 기반의 시계열 예측 모델을 구성하여 정확성 평가를 수행하였다. A사의 제품군 B에 대한 월별 판매 수량 데이터에서 2016년 1월부터 2019년 6월까지를 훈련 데이터로 설정하고, 최근 1년의 기간인 2019년 7월부터 2020년 6월

까지의 데이터를 검증 데이터로 나누어 실험을 진행하였다.

#### 4.1 ARIMA 기법을 이용한 분석모델

ARIMA 모델은 (p, d, q)와 같이 표현되는데 여기서 p는 AR(Auto-regressive) 항의 차수를 의미하고, q는 MA(Moving Average) 항의 차수를 의미하며, d는 차분의 차수를 의미한다. 본 연구에서는 ARIMA의 Best model을 pmdarima. auto\_arma로 추정하였다. Best model을 추정한 결과 ARIMA(1,0,0)가 산출되었다. 그리고 이를 이용하여 매출 데이터를 종속변수로 설정하여 예측 분석을 수행하였다.

<표 2> ARIMA 예측 성능

	ARIMA
MAPE	5.40%
RMSE	2,374,088
RMSLE	0.064


예측결과 MAPE는 5.4%로 나타났고, RMSE는 2,374,088로 나타났으며, RMSLE는 0.0644로 나타났다.

#### 4.2 LSTM 기법을 이용한 예측 모델


LSTM을 이용한 예측 모델은 단변량 예측 모델과 다변량 예측 모델로 구성하였다. 두 LSTM 모델 모두 Month를 더미 변수화하여 sequence 데이터로 만들어 딥러닝에서 용이하게 사용할 수 있도록 하였다. 단변량 LSTM 예측 모델의 활성화 함수는 ReLU를 사용하였으며, 마지막 Hidden Layer에서 50%의 Dropout Layer를 삽입하여 무작위성을 추가하였다. <그림 4>와 같이 단변량 LSTM 예측모형은 월별 판매 수량과 Month의 더미 변수만을 입력변수로 활용하였다.

<그림 5>의 다변량 LSTM 예측 모델은 리모

텔링에 대한 수요 추세를 반영할 수 있는 변수를 추가하여 데이터를 조인(join)한 뒤 모델을 구축하였다. 리모델링 이슈가 가구 부자재 판매량 변화에 유의미한 변인이 될 가능성을 확인함에 따라 전월에 뉴스와 블로그에서 ‘리모델링’이 언급된 문서의 개수를 집계하여 변수로 사용하였다. 또한, KOSIS에서 전월의 월별 건설공사비 지수의 건물 건설 및 건축 보수 항목을 추가로 변수로 사용하였다. 다변량 LSTM 예측 모델에 사용된 데이터의 예시는 <표 3>과 같다.



<그림 4> 단변량 LSTM 예측 Process



<그림 5> 다변량 LSTM 예측 Process

<표 3> 다변량 LSTM 예측 모델 사용 데이터


Month	Remodeling Blog	Remodeling News	Construction cost index	Sales Quantity
2016-01	309,201	7,102	100.66	31,881,560
2016-02	607,511	34,610	100.58	32,565,720
2016-03	830,576	44,192	100.63	32,670,400
...	...	...	...	...
2019-04	2,289,677	78,572	115.84	34,634,800
2019-05	2,047,381	66,100	115.84	35,204,500
2019-06	1,860,866	48,408	115.8	38,930,000

또한, 직전 달의 제품군별 판매량은 다음 달 해당 제품군의 판매 수량에 영향을 미친다는 사실이 확인되어 이전 월의 판매 수량도 입력변수로 추가하였다. 다양한 범주의 변수가 추가되었으므로 변수의 범위를 왜곡하지 않도록 Scaling하여 정상화한 후 학습에 사용하였다.



각 Hidden Layer에서 1024개의 노드를 만들어내도록 설정하였으며, 활성화 함수는 ReLU를 사용하였다. Hidden Layer에 Dropout Layer를 삽입하여 학습에 무작위성을 주었다. Output Layer에서는 sigmoid 함수를 사용하여 결과 값이 0에서 1 사이의 값을 갖도록 지정하였다.

단변량 LSTM 예측 모델과 다변량 LSTM 예측 모델을 이용한 예측결과는 <그림 6>과 같으며 성능평가 지표에 따른 결과는 <표 4>와 같다.



<그림 6> LSTM 예측 결과 그래프

<표 4> LSTM 예측 성능


	단변량 LSTM	다변량 LSTM
MAPE	5.41%	2.81%
RMSE	2,389,227	1,567,698
RMSLE	0.061	0.043

단변량 LSTM의 경우 MAPE가 5.41%로 약간 낮은 성능을 보이지만 ‘Remodeling’의 언급 문서 수와 건설공사비 지수, 전월 판매 수량을 설명변수로 추가한 다변량 LSTM의 경우 MAPE 2.81%로 감소하여 설명변수를 추가했을 때 더 좋은 예측결과를 보이는 것을 확인할 수 있었다. RMSE와 RMSLE 또한 변수를 추가한 예측에서 각각 821,529과 0.018씩 낮아짐을 확인하였다.

### 4.3 1D-CNN 기법을 이용한 예측 모델


1D-CNN 예측 모델은 월별 판매 수량만을 입력변수로 구성하였으며 LSTM 예측 모델과는

달리 Month 변수를 더미화하지 않았다. <그림 7>과 같이 1D-CNN 예측 모델은 과거 3개월의 판매 수량을 입력 변수로 재구조화 하였다. 출력공간의 차원은 64이고, 1D convolution의 창은 2로 설정하였다. 활성화 함수는 ReLU를 사용하였다.



<그림 7> 예측 Process

1D-CNN을 이용한 예측결과는 <그림 8>과 같으며 성능평가 지표에 따른 결과는 <표 5>와 같다.



<그림 8> 1D-CNN 예측결과 그래프


<표 5> 1D-CNN 예측 성능

	1D-CNN
MAPE	5.05%
RMSE	2,172,886
RMSLE	0.058

1D-CNN 예측 모델은 MAPE가 5.05%, RMSE가 2,172,886, RMSLE가 0.058로 나타났다.

실험결과를 종합하여 예측결과 그래프 <그림 9>와 성능평가 지표에 따른 예측 성능 비교 <표 6>를 제시하였다. 예측 모델에서 월별 판매 수량만을 입력변수로 설정한 모델은 ARIMA, 단변량 LSTM, 1D-CNN 모델이다. 이 경우, 1D-CNN 모델의 예측 성능이 가장 우수한 것으로 나타났다. 하지만 다양한 변수를 고려한 다변량 LSTM 예

측 모델과 월별 판매 수량만을 고려한 1D-CNN 모델의 성능을 비교해 보면, 다변량 LSTM 모델의 예측 성능이 더욱 우수한 것으로 나타났다.



〈그림 9〉 LSTM 및 1D-CNN 예측결과 그래프

〈표 6〉 ARIMA 및 LSTM, 1D-CNN 예측 성능 비교

	MAPE	RMSE	RMSLE
ARIMA	5.40%	2,374,088	0.064
단변량 LSTM	5.41%	2,389,227	0.061
다변량 LSTM	2.81%	1,567,698	0.043
1D-CNN	5.05%	2,172,886	0.058

## V. 결론

본 논문에서는 가구 부자재를 생산하고 있는 중소기업 A사를 대상으로 통계적 시계열 예측 기법과 인공지능 기반 시계열 데이터 수요 예측 모델을 제안하였다. 기업 측면에서 수요의 예측은 생산, 자재 및 물류 등의 계획과 관리 측면에서 매우 중요하다. 잘못된 수요 예측으로 자재 주문의 리드 타임이 길어지게 되면 고객의 니즈를 대응하기 어렵고, 경쟁우위를 확보하기 어렵게 된다. 따라서, 고객의 니즈와 트렌드 변화에 따라 정확한 수요 예측을 통한 예측생산이 필요하며, 이를 위해서는 다양한 시계열 변수를 고려하여 수요 예측 모델에 적용할 필요가 있다.

본 연구에서는 시계열 데이터에 대하여 통계적 예측 기법인 ARIMA 분석기법과 인공지능 분석기법인 단변량 LSTM, 다변량 LSTM,

1D-CNN 분석기법을 활용하여 2019년 7월~2020년 6월의 수요량을 예측하고 모델의 성능을 비교하였다. 분석 결과에서 월별 판매 수량만을 입력변수로서 고려한 시계열 예측 모델 중 1D-CNN의 예측 성능이 가장 우수한 것으로 나타났다. 하지만 전월의 뉴스와 블로그에서 리모델링이 언급된 문서의 개수를 집계하고, KOSIS에서 전월의 월별 건설공사비 지수 등 다양한 항목을 추가하여 판매 수요 추세를 반영할 수 있는 다변량 LSTM 예측 모델의 성능이 월별 판매 수량만을 고려한 1D-CNN 예측 모델의 성능보다 우수한 것으로 드러났다. 따라서 수요 예측 시 추세를 반영할 수 있는 다양한 변수들을 통해 다변량 LSTM을 실시하는 것이 바람직하며, 제한적인 조건으로 인해 하나의 입력변수를 고려할 수밖에 없는 경우 1D-CNN을 실시하는 것이 바람직할 것이다.

인공신경망 모델의 특성상 훈련 데이터셋에 의한 영향을 많이 받기 때문에 보다 정확하고 실용성 있는 예측 모델을 구축하기 위해서는 훈련 및 검증에 사용되는 다양한 입력 파라미터를 어떻게 적용할 것인가에 관한 연구를 지속해서 수행할 필요가 있다. 또한, 다양한 입력변수를 고려하여 다변량 LSTM 예측 모델과 다변량 CNN 예측 모델의 정확성 차이를 비교하여 후속 연구를 진행해야 할 것이다.


## 참고 문헌

[1] [http://www.molit.go.kr/USR/NEWS/m\\_71/dtl.js?lcmspage=1&id=95084312](http://www.molit.go.kr/USR/NEWS/m_71/dtl.js?lcmspage=1&id=95084312)  
 [2] 노우리. “전·가구 수요 증가 홈코노미주, 목표 주가도 쑥쑥” 이투데이, 2020.07.10. <https://www.today.o.kr/news/view/1916449>  
 [3] 반상규. “모델링 시장규모 2030년 46조원으로 2.5배 급성장 전망” 대한전문건설신문, 2019.04.02.



- <http://www.koscaj.com/news/articleView.tml?idxno=111927>
- [4] 김정아, 정종필, 이태현, 배상민. (2018). 중소기업 제조공장의 수요예측 기반 재고관리 모델의 효용성 평가, 18(2), 197-207.
- [5] D. Jeong, M. Baek and S. Lee, "Long-term prediction of vehicle trajectory based on a deep neural network," in Proc. of the 2017 International Conference on Information and Communication Technology Convergence (ICTC), Jeju, South Korea, pp. 725-727, 2017. DOI: 10.1109/ICTC.017.8190764
- [6] A. Tokgoz and G. Unal, "A RNN based time series approach for forecasting turkish electricity load," in Proc. of the 2018 26th Signal Processing and Communications Applications Conference (SIU), Izmir, Turkey, 2018. DOI: 10.1109/SIU.018.8404313
- [7] 김진섭, 황재성, 정재우. (2020). 시계열 분해 데이터를 이용한 LSTM 기법 기반 항공기 수리 부속 수요예측 방안 연구. 경영과학, 37(2), 1-18.
- [8] 조영기, 이현수. (2020). 변형된 Attention 메커니즘 기반의 LSTM을 통한 전력수요 예측 프레임워크. 한국지능시스템학회 논문지, 30(3), 242-250.
- [9] 이정현, 김재성, 안영호, 조완섭. (2019). V2G 환경의 전력 수급 의사결정 지원을 위한 SARIMA기법과 LSTM기법의 전력사용량 1일 예측 연구. 한국데이터정보과학회지, 30(4), 779-795.
- [10] 이우주, 장효진, 이서희, 최승희. (2020). 승륜에 대한 Arima와 Grey 그리고 LSTM 모형 비교. 한국지능시스템학회 논문지, 30(4), 303-308.
- [11] 김예인, 이세은, 권용성. (2020). CNN-LSTM 딥러닝 기반 캠퍼스 전력 예측 모델 최적화 단계 제시. 한국산학기술학회 논문지, 21(10), 8-15.
- [12] Y. H. Chen, T. Krishna, J. S. Emer and V. Sze, "Eyeriss: An energy-efficient reconfigurable accelerator for deep convolutional neural networks," IEEE Journal of Solid-State Circuits, vol. 52, no. 1, pp. 127-138, 2017.
- [13] T. D. Do, M. T. Duong, Q. V Dang and M. H. Le, "Real-time self-driving car navigation using deep neural network," in Proc. of the 2018 4th International Conference on Green Technology and Sustainable Development (GTSD), pp. 7-12, 2018. DOI: 10.1109/GTSD.018.8595590
- [14] Bengio, Y., P. Simard, and P. Frasconi, "Learning long-term dependencies with gradient descent is difficult," IEEE Transactions on Neural Networks, Vol.5, No.2(1994), 157-66.
- [15] Arel, I., Rose, D. C., and Kamowski, T. P., "Deep Machine Learning-A New Frontier in Artificial Intelligence Research", IEEE Computational Intelligence Magazine, pp.13-18, Nov. 2010.
- [16] 김현일, 한건연, 이재영. (2020). LSTM 모형과 로지스틱 회귀를 통한 도시 침수 범위의 예측. 대한토목학회논문집, 40(3), 273-283.
- [17] 정호철, 선영규, 이동구, 김수현, 황유민, 심이삭, 오상근, 송승호, 김진영. (2019). 에너지인터넷에서 1D-CNN과 양방향 LSTM을 이용한 에너지 수요예측. 전기전자학회논문지, 23(1), 134-142.
- [18] Chen, Q., Xie, Q., Yuan, Q., Huang, H., & Li, Y. (2019). Research on a Real-Time Monitoring Method for the Wear State of a Tool Based on a Convolutional Bidirectional LSTM Model. Symmetry, 11(10), 1233.

저자 소개



**김재성(Jae-Sung Kim)**

- 2017년: 충북대학교 경영정보학과 (박사)
- 2017년~현재: 충북대학교 빅데이터학과 교수
- 관심분야: 빅데이터, 알고리즘, 데이터마이닝



**양여진(Yeo-Jin Yang)**

- 2020년: 충북대학교 국제경영학과 (학사)
- 2020년~현재: 충북대학교 빅데이터협동과정 (석사)
- 관심분야: 딥러닝, 머신러닝



**오민지(Min-Ji Oh)**

- 2017년: 이화여자대학교 교육공학과 (학사)
- 2020년~현재: 충북대학교 빅데이터협동과정 (석사)
- 관심분야: 빅데이터, 머신러닝



**이성웅(Sung-Woong Lee)**

- 2014년: 한국교통대학교 경영학과 (학사)
- 2019년: 한국기술교육대학교 기계설비제어공학과 (석사)
- 2013년~현재: 새한(주) 경영기획팀 파트장

- 관심분야: 빅데이터, ERP(MES), 통계



**권순동(Sun-dong Kwon)**

- 2002년: 서울대학교 경영학과 경영학 (박사)
- 2004년~현재: 충북대학교 경영정보학과 교수
- 관심분야: 정보보호, 전자상거래 전략, SCM, 스마트팩토리 전략



**조완섭(Wan-Sup Cho)**

- 1996년: KAIST 전산학과 (박사)
- 1997년~현재: 충북대학교 경영정보학과 교수
- 관심분야: 데이터베이스, 빅데이터, 블록체인, 인공지능, 데이터 거버넌스