

LSTM과 Bi-LSTM을 사용한 비주기성 시계열 데이터 예측 성능 비교 분석

Comparative Analysis of Prediction Performance of Aperiodic Time Series Data using LSTM and Bi-LSTM

이주형¹ · 홍준기^{2*}

배재대학교 모바일소프트웨어학과¹, 배재대학교 컴퓨터공학과²

요약

온라인 쇼핑의 대중화로 인해 많은 의류 상품이 온라인 쇼핑을 통해 소비된다. 의류 상품은 다른 상품과 달리 판매량이 일정하지 않고 날씨의 변화에 따라 판매량이 변화하는 특징이 있다. 따라서 의류 상품의 머신 러닝을 적용한 효율적인 재고 관리 시스템에 대한 연구는 매우 중요하다. 본 논문에서는 의류 업체 'A'로부터 실제 의류 상품 판매량 데이터를 수집하고 판매량 데이터와 같은 시계열 데이터의 예측에 많이 활용되는 LSTM(Long Short-Term Memory)과 Bidirectional-LSTM(Bi-LSTM)의 학습에 사용하여 LSTM과 Bi-LSTM의 판매량 예측 효율을 비교 분석하였다. 시뮬레이션 결과를 통해 LSTM 기술 대비 Bi-LSTM은 시뮬레이션 시간은 더 많이 소요되지만 의류 상품 판매량 데이터와 같은 비주기성 시계열 데이터의 예측 정확도가 동일하다는 것을 확인하였다.

■ 중심어 : LSTM, Bidirectional-LSTM, 비주기성 시계열 데이터, 예측

Abstract

Since online shopping has become common, people can easily buy fashion goods anytime, anywhere. Therefore, consumers quickly respond to various environmental variables such as weather and sales prices. Therefore, utilizing big data for efficient inventory management has become very important in the fashion industry. In this paper, the changes in sales volume of fashion goods due to changes in temperature is analyzed via the proposed big data analysis algorithm by utilizing actual big data from Korean fashion company 'A'. According to the simulation results, it was confirmed that Bidirectional-LSTM(Bi-LSTM) compared to LSTM(Long Short-Term Memory) takes more simulation time about more than 50%, but the prediction accuracy of non-periodic time series data such as clothing product sales data is the same.

■ Keyword : LSTM, Bidirectional-LSTM, aperiodic time series data, prediction

2022년 12월 02일 접수; 2022년 12월 09일 수정본 접수; 2022년 12월 09일 게재 확정.

* 본 과제(결과물)는 2022년도 교육부의 재원으로 한국연구재단의 지원을 받아 수행된 지자체-대학 협력기반 지역혁신 사업의 결과입니다.(2021RIS-004)

† 교신저자 (jkhong@pcu.ac.kr)

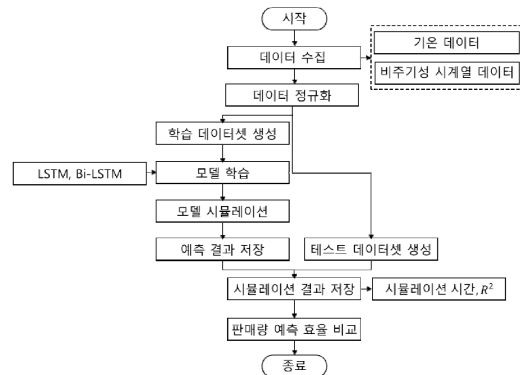
I. 서론

한국의 과학기술정보통신부에서 2019년 4월 발표한 ‘2019 인터넷이용실태조사 보고서’에 따르면, 온라인 매장에서 소비되는 가장 인기 있는 품목은 ‘의류, 신발, 스포츠용품 및 악세서리’가 80.9%로 가장 높은 것으로 조사되었다. 이처럼 시간과 장소에 구애받지 않는 온라인 쇼핑의 대중화로 많은 소비자들이 온라인 쇼핑을 통해 의류 관련 상품들을 구매하는 것을 확인할 수 있다 [1]. 특히 의류 제품의 경우, 가전 제품이나 생활 필수품 제품과 같은 기타 제품들과 달리 기온의 변화에 따라 빠르게 반응하여 그 판매량이 변화한다 [2]. 이러한 의류 제품의 특징으로 인해 의류 제품의 재고 관리는 매우 중요하다. 따라서 기존에 의류 상품의 효율적인 재고 관리를 위해 다양한 머신러닝 기술들을 적용하여 판매량을 예측하는 연구가 진행되었다 [3-7]. 하지만 LSTM과 Bidirectional-LSTM (Bi-LSTM) 기술을 이용하여 실제 온라인 매장의 의류 판매량 데이터를 예측하고 각 기술의 시간 대비 예측 정확도로부터 효율을 비교하는 연구는 아직 진행되지 않았다. 따라서 본 연구에서는 2022년 10월 기준 약 250만 명의 가입자를 보유하고 있는 한국의 의류 업체 ‘A’에서 2014년 1월부터 2018년 12월까지 총 4년간 수집된 의류 상품의 실제 판매량 데이터를 LSTM과 Bi-LSTM 기술들을 통해 예측하고 시물레이션 시간 대비 예측 정확도로부터 각 기술의 효율을 비교 분석한다. 본 논문의 구성은 다음과 같다. 2장에서 제안한 판매량 예측 모델과 수집된 데이터에 대해 설명하고 3장에서 예측에 사용된 LSTM과 Bi-LSTM의 구조에 대해 설명하며, 4장에서 시물레이션 결과에 대해 설명한다. 마지막으로 5장에서 본 논문의 결론을 맺는다.

II. 방법론

2.1 제안한 비주기성 시계열 데이터 예측 모델

본 절에서는 LSTM과 Bi-LSTM 기술들을 이용하여 의류 상품의 판매량을 예측할 때의 효율을 비교 분석하기 위해 제안한 판매량 예측 모델과 예측된 판매량의 정확도를 평가하기 위한 결정계수에 대해 설명한다. 아래 그림 1은 제안한 비주기성 시계열 데이터 예측 모델의 순서도를 나타낸다.



〈그림 1〉 제안한 비주기성 시계열 데이터 예측 모델


그림 1에 따르면, 제안한 판매량 예측 모델은 한국 기상청의 ‘날씨 누리’로부터 일일 평균 기온 데이터를 수집하고 의류 업체 ‘A’로부터 비주기성 시계열 데이터에 해당하는 의류 상품의 판매량 데이터를 수집한다. 또한 수집한 데이터로부터 신경망이 학습할 수 있는 형태로 전처리를 수행하여 학습 데이터셋과 테스트 데이터셋을 생성하며, 생성된 학습 데이터를 학습하고 예측된 결과로부터 계산된 결정계수 값과 시물레이션에 소요된 시간을 저장한다. 마지막으로 저장된 결정계수 값과 시물레이션 시간으로부터 LSTM과 Bi-LSTM의 비주기성 데이터 예측 성능을 비교한다.

2.2 의류 상품 판매량 데이터 수집

본 절에서는 의류 업체 ‘A’로부터 수집한 의류 상품의 판매량 데이터와 일일 평균 기온 데이터에 대해 설명한다. 일일 평균 기온 데이터는 기상청 ‘날씨누리’로부터 수집되었다. 판매량 데이터와 일일 평균 기온 데이터는 각각 1460개의 데이터로 구성되며 0과 1사이 범위의 최소-최대 정규화 과정이 1460개의 데이터에 모두 적용된다. 정규화에 사용된 수식은 아래 수식 1과 같다.

$$x_{norm} = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (1)$$

수식 1에서 x 와 x_{norm} 은 각각 정규화 과정을 거치지 않은 데이터와 정규화 과정을 거친 데이터를 의미한다. 아래 그림 2는 정규화된 판매량 데이터와 일일 평균 기온 데이터를 시각화한 그래프이다.




〈그림 2〉 수집된 비주기성 시계열 데이터와 평균 기온 데이터

그림 2의 검은색 그래프는 4년간 수집된 반바지 판매량 데이터를 나타내며, 회색 그래프는 평균 기온 데이터를 나타낸다. 그림 2에 따르면, 기온 변화에 따른 반바지 판매량은 기온이 증가할수록 판매량이 증가하지만 일정한 주기성은 나타나지 않는 것을 확인하였다. 다음 절에서는 제한한 비주기성 시계열 데이터를 예측하기 위해 제안한 모델에 사용되는 LSTM과 Bi-LSTM 기술들에 대해 설명한다.

2.3 LSTM

기존 RNN(Recurrent Neural Network)은 긴 sequence data를 학습할 경우 신경망의 깊이가 깊어지게 되어 기술기 소실이 발생하는 장기의존성 문제를 갖고 있다. LSTM은 이러한 RNN의 단점을 해결하기 위해 고안된 기술이다 [8]. 아래 그림 3은 LSTM의 구조를 나타낸다.



〈그림 3〉 LSTM 구조

그림 4의 C, t, x, h 는 각각 Cell state, time step, 입력 값, 출력 값을 의미하며, f, i, o 는 각각 망각 게이트, 입력 게이트, 출력 게이트를 의미한다. LSTM은 RNN의 장기의존성 문제를 3개의 게이트와 Cell state를 통해 해결한다. 여기서 LSTM의 Cell state는 다음 LSTM Cell로 정보를 그대로 전달하는 역할을 수행한다. 이러한 Cell state 연산을 포함하여 LSTM에서 수행되는 연산의 수식은 아래와 같다.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (4)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (5)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (6)$$

$$h_t = o_t \odot \tanh(C_t) \quad (7)$$

여기서 수식 2, 3, 4, 5의 W 와 b 는 각각 가중치 행렬과 편향 벡터를 나타낸다. 수식 2는 망각 게이트 연산을 의미하며, 이전 시점으로부터 전달 받은 Cell state의 정보 중에서 잊어버릴 정보를 정하는 역할을 수행한다. 망각 게이트는 이전 시점의 은닉 상태인 h_{t-1} 과 현재 시점의 입력인 x_t 를 입력으로 받아 시그모이드 함수(Sigmoid function)를 취해준 값을 출력으로 갖게 된다. 이러한 망각 게이트의 출력은 시그모이드 함수가 적용되었기 때문에 0과 1사이의 값을 가지며, 이 값이 클수록 Cell state의 정보가 오래 유지되고 이 값이 작을수록 정보가 빠르게 사라진다.


수식 3은 입력 게이트 연산을 의미하며, 전달 받은 이전 시점의 Cell state 중, 사용할 정보를 결정하는 역할을 수행한다. 수식 5의 \tilde{C}_t 가 Cell state에 더해질 새로운 후보 값들에 해당하고, 입력 게이트의 출력은 수식 6에서 \tilde{C}_t 와 곱해져 사용할 정보가 결정된다.

수식 4는 출력 게이트 연산을 의미하며, 업데이트된 Cell state에서 내보낼 값을 결정하는 역할을 수행한다. 최종적으로 수식 6에서 망각 게이트의 출력 값과 이전 시점의 Cell state에 Element-wise-product가 수행되어 이전 시점의 Cell state에서 사용할 정보가 결정되고 입력 게이트의 출력 값과 Cell state에 더해질 후보 값들에 Element-wise-product가 수행되어 후보 값들 중 사용할 정보가 결정된다.

이러한 두 개의 값으로 업데이트된 Cell state에 Hyperbolic Tangent 함수가 취해진 값과 출력 게이트의 출력 값에 Element-wise-product가 수행되어 현재 시점의 출력 값이 계산되어 다음 시점으로 전달된다. 이와 같은 계산이 매 시점마다 수행되며, 마지막 시점에서 수행된 계산의 결과가 예측 값에 해당한다.

2.4 Bi-LSTM

Bidirectional은 일반적으로 RNN 기술과 결합되어 사용되는데, 본 연구에서는 Bidirectional이 LSTM과 결합된 형태인 Bi-LSTM을 사용한다 [9]. Bi-LSTM은 독립적인 두 개의 은닉층으로 구성되며 아래 그림 4는 Bi-LSTM이 예측 값을 생성하는 과정을 나타낸다.



〈그림 4〉 Bi-LSTM 구조

그림 4의 x, y, t 는 각각 입력 값, 출력 값, time step을 의미한다. Bidirectional이 적용된 LSTM은 순방향 연산뿐만 아니라 역방향 연산에서도 학습에 사용하기 위한 정보를 얻을 수 있기 때문에 일반적으로 LSTM보다 향상된 예측 정확도를 보이지만 시뮬레이션 시간이 증가한다는 단점이 존재한다.

III. 시뮬레이션 결과

본 장에서는 제안한 비주기성 시계열 데이터 예측 모델에서 LSTM과 Bi-LSTM을 사용하여 40%, 60%, 80% 구간의 판매량 데이터를 학습할 때, 각각 나머지 60%, 40%, 20%에 해당하는 구간을 예측한 결과를 설명한다. 또한 예측한 결과로부터 계산된 결정계수 값과 예측에 소요된 시뮬레이션 시간으로부터 LSTM과 Bi-LSTM의 예측 성능을 비교 분석한다.

3.1 시뮬레이션 환경

본 절에서는 제안한 비주기성 시계열 데이터 예측 모델을 사용하여 판매량을 예측하는 시뮬레

이션이 수행된 환경과 시뮬레이션에 사용된 신경망에 공통으로 적용된 매개변수의 값을 설명한다. 아래의 표 1은 시뮬레이션이 수행된 환경 요소와 환경 사양을 나타낸다.

〈표 1〉 시뮬레이션 환경

환경 요소	환경 사양
CPU	Intel(R) Xeon(R) CPU @ 2.00GHz
GPU	NVIDIA Tesla T4
Memory	26 GB
Simulation Tools	Google Colaboratory Pro/ Python 3.7.13/Tensorflow 2.8.2

아래의 표 2는 시뮬레이션에 사용된 신경망에 공통으로 적용된 매개변수의 값을 나타낸다.


〈표 2〉 시뮬레이션 설정

시뮬레이션 매개변수	값
은닉 유닛 개수	32
초기 학습률	0.0002
Epoch 수	10
최소 배치 크기	32
Optimizer	Adam [11]
반복 횟수	10

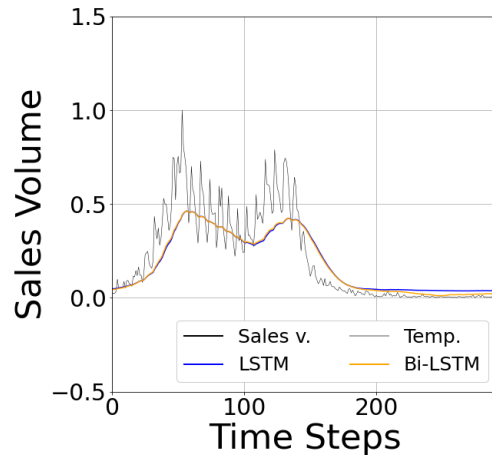
동일한 시뮬레이션 환경에서 LSTM과 Bi-LSTM의 성능 차이를 확인하기 위해 모든 매개변수의 값들은 모두 동일하게 설정하였다. 또한 표 2의 Epoch 수와 초기 학습률은 학습 데이터의 크기에 따른 성능차이를 뚜렷하게 확인할 수 있도록 설정하였다. 또한 최소 배치 크기는 32에서 128이 권장되고 있기 때문에 32로 설정하였으며 [10], 지역 최소점 문제 발생을 방지하고 원활한 최적화가 이루어질 수 있도록 할 목적으로 Adam (Adaptive Moment Estimation) 최적화 알고리즘을 사용하였다 [11].

3.2 시뮬레이션 결과

본 절에서는 제안한 비주기성 시계열 데이터 예측 모델로 예측된 결과와 예측된 결과로부터 계산된 결정계수 값, 그리고 예측에 소요된 시뮬레이션 시간을 설명하고 최종적으로 LSTM과 Bi-LSTM의 판매량 예측 효율을 비교 분석한다. 아래 그림 5와 그림 6은 LSTM과 Bi-LSTM을 사용하여 40%, 60%, 80%를 학습하여 예측한 결과 중, 80%의 판매량 데이터를 학습하고 나머지 20%의 판매량 데이터를 예측한 시뮬레이션 결과이다.



(a)



(b)

〈그림 5〉 (a) 비주기성 시계열 데이터의 예측 결과 (b)확대

그림 5의 판매량 예측 결과에서 판매량 데이터의 80%를 학습했음에도 LSTM과 Bi-LSTM의 예측 정확도가 거의 다르지 않은 것을 알 수 있다. 다음 절에서 학습 데이터 크기에 따른 예측 정확

도의 변화를 자세히 설명한다.

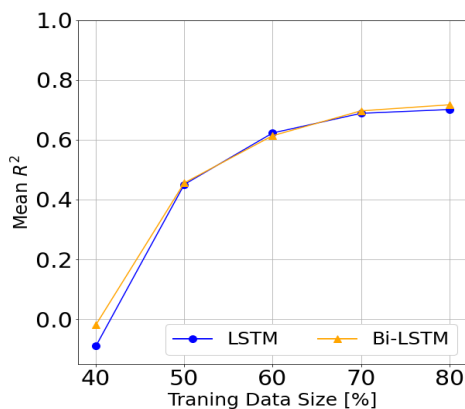
3.3 평균 결정계수 비교 분석

본 절에서는 학습 데이터 크기 별 예측 결과로부터 계산된 평균 결정계수 값을 설명한다. 아래 수식 8은 결정계수 값의 수식을 나타낸다.

$$R^2 = \frac{\sum_{i=1}^N (y_i - \hat{y})^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (8)$$

수식 8의 N , y_i , \hat{y} , \bar{y} 는 각각 판매량 데이터의 개수, 실제 판매량 데이터, 예측된 판매량 데이터, 판매량 데이터의 평균 값을 나타낸다.

아래의 그림 7은 학습 데이터의 크기가 50%, 70%일 때 각각 50%, 30%를 예측했을 때의 결과를 추가하여 학습 데이터의 크기에 따른 평균 결정계수 값의 변화를 관찰할 수 있도록 한 그래프이다. 평균 결정계수 값은 각 학습 구간 별로 10번의 시뮬레이션이 수행된 결과로부터 계산되었다.



〈그림 6〉 학습 데이터의 크기에 따른 평균 결정계수 값

그림 6에서 LSTM과 Bi-LSTM 모두 학습 데이터의 크기가 증가함에 따라 평균 결정계수 값도

증가하는 것은 동일하지만, Bi-LSTM이 LSTM에 비해 학습에서 얻을 수 있는 정보의 양이 더 많음에도 불구하고 평균 결정계수 값의 차이는 약 1%로 매우 유사한 것을 확인했다.

이러한 시뮬레이션 결과를 통해 의류 상품의 판매량 데이터와 같이 주기성이 나타나지 않는 시계열 데이터는 Bi-LSTM의 정확도가 LSTM과 유사한 정도임을 알 수 있다. 다음 절에서 정확한 평균 결정계수 값과 시뮬레이션 시간으로부터 LSTM과 Bi-LSTM의 비주기성 시계열 데이터 예측 효율을 비교 분석한다.

3.4 시뮬레이션 소요 시간 대비 예측 정확도 비교 분석

본 절에서는 LSTM과 Bi-LSTM을 사용해 40%, 60%, 80%의 판매량 데이터를 학습하고 각각 나머지 60%, 40%, 20%를 예측한 경우의 평균 결정계수 값과 평균 시뮬레이션 시간으로부터 시간 대비 예측 정확도를 비교 분석한다. 아래의 표 3은 LSTM과 Bi-LSTM의 평균 결정계수 값과 평균 시뮬레이션 시간을 나타낸다.

〈표 3〉 학습 데이터의 크기에 따른 평균 결정계수 값과 평균 시뮬레이션 시간

학습 구간	예측 모델	R^2	시뮬레이션 시간(s)
40%	LSTM	0.543	6.9
	Bi-LSTM	0.536	10.5
60%	LSTM	0.725	7.8
	Bi-LSTM	0.743	12.1
80%	LSTM	0.808	8.8
	Bi-LSTM	0.800	13.5

표 3에서 LSTM과 Bi-LSTM 모두 학습 데이터의 크기가 증가함에 따라 평균 시뮬레이션 시간이 증가하였으므로, 적은 학습 데이터만으로도 높은 정확도의 예측을 하는 기술을 예측 효율이

좋은 기술로 정의 할 수 있다. 아래의 표 4는 LSTM 대비 Bi-LSTM의 평균 결정계수 값과 평균 시뮬레이션 시간의 변화율을 나타낸다.

〈표 4〉 LSTM 대비 Bi-LSTM의 평균 시뮬레이션 시간 대비 평균 결정계수 값 변화율

학습 구간	R^2	시뮬레이션 시간
40%	-1.29%	+52.6%
60%	+2.48%	+54.8%
80%	-0.99%	+53.4%

표 4에서 학습 데이터의 크기가 40%인 경우, Bi-LSTM의 평균 결정계수는 LSTM의 평균 결정계수보다 1.29% 감소하였으며, 평균 시뮬레이션 시간은 52.6% 증가하였다. 또한 학습 데이터의 크기가 60%일 때, Bi-LSTM의 평균 결정계수는 LSTM의 평균 결정계수보다 2.48% 증가하였지만, 평균 시뮬레이션 시간은 54.8% 증가하였다. 마지막으로, Bi-LSTM이 80%의 데이터를 학습하였을 때, 평균 결정계수가 LSTM의 평균 결정계수보다 0.99% 감소하였으며, 평균 시뮬레이션 시간은 53.4% 증가하였다. 따라서 모든 학습 구간에서 Bi-LSTM의 평균 결정계수는 LSTM과 유사한 수준이며, Bi-LSTM의 평균 결정계수가 가장 많이 증가하였을 때에도 정확도 증가량이 3%에 미치지 못하는 것을 확인했다. 평균 시뮬레이션 시간의 경우는 Bi-LSTM이 모든 학습 구간에서 LSTM보다 긴 것으로 나타났다. 이처럼 Bi-LSTM의 판매량 예측 효율보다 LSTM의 판매량 예측 효율이 높은 결과가 관찰되는 이유는 다음과 같은 것으로 확인했다.

Bi-LSTM은 예측 성능을 향상시키기 위해 LSTM에 역방향 연산을 수행하는 LSTM 계층을 추가한 형태이다. 따라서 Bi-LSTM은 순방향 뿐만 아니라 역방향으로부터도 학습에 적용할 수 있는 정보를 수집하기 때문에 LSTM보다 학습에 사용하는 정보의 양이 많아진다. 하지만, 판매량

데이터와 같이 주기성이 나타나지 않는 시계열 데이터의 경우, Bi-LSTM의 역방향 연산으로부터 관련성이 없는 정보가 수집되어 학습에 반영되기 때문에 유의미한 성능 향상 효과를 보기 어렵다. 따라서 주기성이 나타나지 않는 시계열 데이터에서는 Bi-LSTM의 예측 효율이 떨어진다.

IV. 결 론

본 논문에서는 LSTM과 Bi-LSTM 기술을 사용해 의류 상품의 판매량과 같은 비주기성 시계열 데이터를 예측하는 모델을 제안하고 판매량을 예측한 결과와 예측하는데 소요된 시간으로부터 LSTM과 Bi-LSTM의 판매량 예측 효율을 비교 분석하였다. 시뮬레이션 결과에 따르면, LSTM의 평균 결정계수 값과 Bi-LSTM의 평균 결정계수 값이 서로 유사하지만, 평균 시뮬레이션 시간의 경우 Bi-LSTM이 LSTM보다 약 50% 증가한 것으로 나타났다. 이러한 시뮬레이션 결과를 통해 LSTM의 판매량 예측 효율이 Bi-LSTM 보다 우수한 것을 알 수 있으며, 그 이유는 Bi-LSTM이 학습에 반영하기 위해 수집하는 역방향 정보는 주기성이 나타나지 않는 의류 상품 판매량 데이터로부터 얻어졌으며, 이로 인해 관련성이 떨어지는 정보가 학습에 반영되어 역효과가 일어났기 때문에 평균 결정계수 값이 증가하지 않았고 평균 시뮬레이션 시간만 늘어난 것으로 확인하였다. 따라서, 본 연구의 시뮬레이션 결과를 통해 Bi-LSTM을 통해 비주기성 시계열 데이터를 예측할 때 시뮬레이션 소요 시간 대비 LSTM보다 높은 예측 정확도를 갖지 못하는 것을 확인하였으며, Bi-LSTM은 의류 상품의 재고 관리를 위한 판매량 데이터 예측 시스템에 활용될 모형으로 부적합 것을 확인하였다. 따라서 향후 GRU와 Attention-Mechanism 기술을 적용한 RNN 기술들을 사용하여 비주기성 시계열 데이터 예측 효율을 비교 분석하는 연구를 진행할 예정이다.

사 사

본 과제(결과물)는 2022년도 교육부의 재원으로 한국연구재단의 지원을 받아 수행된 지자체-대학 협력기반 지역혁신 사업의 결과입니다. (2021RIS-004)

참 고 문 헌

[1] Ministry of Science and ICT(MSIT) and Korea Internet and Security Agency(KISA), 2018 Survey on the Internet Usage, 2019.

[2] N. Liu, S. Ren, T.-M. Choi, C.-L. Hui, and S.-F. Ng, "Sales Forecasting for Fashion Retailing Service Industry: A Review," *Mathematical Problems in Engineering*, Vol. 2013, pp. 1-9, 2013.

[3] A.L.D. Loureiro, V.L. Miguéisa, Lucas F.M. da Silva, "Exploring the use of deep neural networks for sales forecasting in fashion retail," *Decision Support Systems*, Vol. 114, pp. 81-93, 2018.

[4] E. Tarallo, G. K. Akabane, C. I. Shimabukuro, J. Mello, D. Amancio, "Machine Learning in Predicting Demand Fast-Moving Consumer Goods: An Exploratory Research," *IFAC-PapersOnLine*, Vol. 52, pp. 737-742, 2019.

[5] M. Xia, Y. Zhang, L. Weng, X. Ye, "Fashion retailing forecasting based on extreme learning machine with adaptive metrics of inputs," *Knowledge-Based Systems*, Vol. 36, pp. 253-259, 2012.

[6] C. Giri, Y. Chen, "Deep Learning for Demand Forecasting in the Fashion and Apparel Retail Industry," *forecasting*, Vol. 4, pp. 565-581, 2022.

[7] J. M. Chae, E. H. Kim, "Sales Forecasting Model for Apparel Products Using Machine Learning

Technique," *Fashion & Textile Research Journal*, Vol. 23, pp. 480-490, 2021.

[8] S. Hochreiter, J. Schmidhuber, "Long Short-Term Memory," *Neural Computation*, Vol. 9, pp. 1735-1780, 1997.

[9] M. Schuster, K. Paliwal, "Bidirectional recurrent neural networks," *IEEE Transactions on Signal Processing*, Vol. 45, pp. 2673-2681, 1997.

[10] Y. Wu, J. Johnson, "Rethinking"Batch "in BatchNorm," *arXiv*, Vol. 1, 2021, arXiv: 2105.07576.

[11] D. P. Kingma, J. Ba, "Adam: A Method for Stochastic Optimization," *arXiv*, Vol. 9, 2015, arXiv:1412.6980.

저 자 소 개



이 주 형(Ju-Hyung Lee)

·2022년 3월~현재 : 배재대학교 모바일소프트웨어학과 (학사)
 <관심분야> : 인공지능, 비지도 학습, 이미지 분석 등



홍 준 기(Jun-Ki Hong)

·2010년 11월: Carleton University 컴퓨터 시스템 공학과 (학사)
 ·2010년 9월~2017년 2월: 연세대학교 전기전자공학과 (박사)
 ·2016년 8월~2017년 7월 : 한국정보통신기술협회(TTA) 선임연구원
 ·2017년 8월~2020년 2월 : 영산대학교 전기전자공학과 조교수
 ·2020년 3월~현재 : 배재대학교 컴퓨터공학과 조교수
 <관심분야> : 빅데이터, 인공지능, 모빌리티 등