

양방향 LSTM기반 시계열 특허 동향 예측 연구

A patent application filing forecasting method based on the bidirectional LSTM

최 승 완*, 김 광 수**, 곽 수 영**★

Seungwan Choi*, Kwangsoo Kim**, and Sooyeong Kwak**★

Abstract

The number of patent application filing for a specific technology has a good relation with the technology's life cycle and future industry development on that area. So industry and governments are highly interested in forecasting the number of patent application filing in order to take appropriate preparations in advance. In this paper, a new method based on the bidirectional long short-term memory(LSTM), a kind of recurrent neural network(RNN), is proposed to improve the forecasting accuracy compared to related methods. Compared with the Bass model which is one of conventional diffusion modeling methods, the proposed method shows the 16% higher performance with the Korean patent filing data on the five selected technology areas.

요 약

특정 분야의 특허출원수는 기술의 수명주기 및 산업의 활성화 정도와 밀접한 관계를 가지고 있다. 따라서 사전에 사업을 준비하는 기업들과 미래 유망 기술을 초기 단계에서 선별하여 투자하고자 하는 정부 기관들은 미래의 특허 출원수 예측에 대해 큰 관심을 가지고 있다. 본 논문에서는 시계열 데이터에 적합한 RNN의 기법 중 하나인 양방향 LSTM 기법을 이용하여 기존 예측 방법들보다 정확도를 높이는 방법을 제안한다. 5개 분야의 대한민국 특허 출원 데이터에 대해서 제안된 방법은 기존에 사용되던 확산 모델 중 하나인 Bass 모델과 비교하여 평균 절대 백분율 오차(MAPE)의 값이 약 16퍼센트 향상된 결과를 보여준다.

Key words : Patent analysis, Forecasting emerging technology, Deep learning, Bidirectional LSTM Neural Network, Bass Model

1. 서론

어떤 기술의 특허 출원수를 분석하여 기술의 주기를 도입기, 성장기, 성숙기, 쇠퇴기로 구분하는 것을 기술의 수명 주기라 한다[1]. 기술의 수명 주기는 어떤 특정한

기술 분야에서의 혁신이 사회 시스템 내에서 확산하는 정도를 예측하게 해주는데, 일반적으로 확산의 형태를 시간에 따른 누적 그래프로 표현하면 S자 모양의 곡선 형태를 띄게 되고 이를 성장 곡선 모형이라고 한다[2]. 급변하는 시장에서 미래 유망기술을 사전에 발견하고 대

* R&D Team, Saeron S&I

** Dept. of Electronic Engineering, Hanbat National University

★ Corresponding author

E-mail : sykwak@hanbat.ac.kr, Tel : +82-42-821-1167

※ Acknowledgment

This research was supported by the research fund of Hanbat National University in 2019.

Manuscript received Oct. 19, 2022; revised Oct. 19, 2022; accepted Oct. 24, 2022.

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.

비하고자 하는 수많은 기업체와 정부 기관은 이러한 기술의 수명 주기와 확산 정도에 관심을 기울일 수밖에 없다. 또한, 특허 업무를 담당하는 특허청에서는 가용한 자원을 효과적으로 배치하기 위해 특허 출원수를 예측해야 할 직접적인 필요성도 가지고 있다[3].

기술의 확산과 미래 특허 출원수를 예측하는 방법은 크게 전문가들의 설문 조사 등을 통한 정성적인 방법과 데이터에 기반한 정량적인 방법으로 나눌 수 있다. 정량적인 방법의 한 예로 김도희 등은 확산 모형 중 Bass 모형과 Logistics 모형을 이용하여 특허 출원수를 예측하고 그 성능을 비교하였다[4]. Bass 모형과 Logistics 모형 모두 수요 확산을 예측하기 위한 수단으로 만들어진 것인데 이를 특허 출원수 예측에 적용한 것이다.

하지만 이러한 확산 모형은 특정 기간 동안의 특허 출원 수만을 이용하기 때문에 기타 다른 요인에 따른 추세 변화를 예측하기 어려운 점이 있다. 또한 다양한 확산 모형이 존재하지만 모두 적절한 파라미터들을 선정하는 회귀식을 찾는 문제라는 공통점이 존재하며, 확산 모형의 성능은 바로 이 파라미터들을 적절하게 선정하였는지에 따라 크게 달라진다. 이에 따라 확산 모형에 대한 최적의 파라미터들을 찾는 연구들이 있다[5].

이러한 문제점에 대한 대안으로 인공 지능 기법을 활용한 방법들이 제안되어 왔다[6-11]. 신경망 구조를 사용하게 되면 특허 출원 수 외에 얼마든지 원하는 개수만큼의 요인들을 입력으로 사용할 수 있고, 신경망 학습 과정 자체가 최적화 과정을 포함하고 있다는 장점이 있어 기존의 확산 모형을 이용한 방법에 비해 예측 정확도를 향상시킬 수 있을 것으로 기대할 수 있다.

여러 신경망 구조 중에 RNN은 특히 시계열 특성을 갖는 데이터의 학습과 예측에 적합한 신경망 유형이며 LSTM은 RNN의 한 구조이다[12][13]. 본 논문에서는 RNN의 장기의존성 문제를 해결하고 단방향 LSTM이 최근 데이터의 패턴에 너무 강하게 영향을 받는 문제점을 개선한 양방향 LSTM을 이용하여 앞으로의 특허 출원수를 예측하는 방법을 제안하며, 구체적인 내용을 2장에서 설명하였다.

제안하는 방법의 성능을 검증하기 위해 1999년부터 2018년 까지 대한민국 특허청에 출원된 다섯 가지 분야의 데이터셋을 이용하여 확산 모형 중 하나인 Bass 모델의 예측값과 제안된 방법의 예측값을 비교하였다. 3장에서는 실험에 사용한 데이터셋과 실험 환경 및 방법에 대해 설명하고 실험 결과를 정리하였다.

II. 양방향 LSTM을 이용한 특허출원 예측

1. RNN(Recurrent Neural Network)

RNN은 단순한 신경망에 시간적인 개념을 추가한 네트워크로서, 이전상태의 출력을 다시 다음 입력으로 사용하는 구조를 가진 순환뉴런을 이용하고 있다[12]. Fig. 1(a)에 나타난 것처럼 RNN은 새로 입력되는 데이터와 이전 단계의 결과를 함께 처리하는 단계를 반복한다. 이전 데이터가 다음 데이터에 어떤 영향을 주는가를 학습하기 때문에 시간 순서대로 주어지는 시계열 데이터에 대한 학습과 예측에 적합한 모델이다.

하지만 이러한 RNN은 장기적인 데이터에 대해 단점이 존재한다. 과거 방향으로 기울기를 전달하는 과정에서 활성화 함수들의 미분 값들은 0으로 수렴하게 되는데, 기울기가 0에 가까운 값으로 곱해지면 이전 계층의 기울기들도 0으로 수렴하게 된다. 따라서 시간이 지나면서 기울기가 아예 사라져 버리는 장기의존성 문제가 발생한다[14].

2. LSTM(Long Short Term Memory)

LSTM은 기존 RNN의 입력 데이터의 위치 차이가 커질 때 발생하는 데이터 손실을 해결하기 위해 Fig. 1(b)에 나타난 것처럼 RNN의 반복 모듈을 단순 레이어가 아닌 네 개의 레이어가 서로 정보를 주고받는 구조를 가진다[15]. Cell state는 정보가 바뀌지 않고 그대로 흐르도록 하는 역할을 수행한다.

Forget gate는 과거의 정보를 삭제하기 위한 gate이다. 입력으로는 h_{t-1} 과 x_t 를 입력으로 받아 시그모이드 함수를 통과하면, 시그모이드 함수의 출력 범위는 0에서 1 사이이기 때문에 그 값이 0이면 이전상태의 정보는 삭제되고, 1이면 이전상태의 정보를 기억하게 된다.

Input gate는 현재 정보를 기억하기 위한 gate이다. Input gate에는 두 개의 계층이 있으며, 하나는 h_{t-1} 과 x_t 를 입력으로 받아 시그모이드 계층으로 연산하여 0~1 사이의 값을 출력한다. 값이 0이면 데이터는 삭제하고 값이 1인 데이터는 업데이트한다. 나머지 하나는 같은 입력을 tanh 함수로 연산하여 -1~1 사이의 값을 출력한다. 이 계층에서는 cell state에 영향을 주기 위해서 더해질 요소들이 새로 추가되는 정보로서의 가치가 얼마나 큰지를 판단한다. 즉 시그모이드 계층에서는 데이터를 업데이트 할 것인지 안 할 것인지를 결정하며, tanh 계층에서는 업데이트되는 정보의 가치의 강도를 부여한다. Output gate는 출력 값인 h_t 에 영향을 준다. 먼저




Fig. 1. The basic RNN and LSTM architecture [18].
그림 1. RNN과 LSTM의 구조[18]

Output gate의 입력은 h_{t-1} 과 x_t 를 입력받고, 이 값을 시그모이드 계층에 입력하여 값이 0이면 데이터를 출력하지 않으며, 값이 1이면 입력된 데이터를 출력데이터로 사용한다는 의미이다. 이후 이 값을 이용하여 최종적으로 출력되는 h_t 값에 영향을 주어 다음 단계의 입력을 제어한다. 하지만 이러한 LSTM은 입력의 순서를 시간 순서대로 입력시키기 때문에 출력되는 결과가 직전 타임패턴의 영향을 강하게 받는다는 한계가 있다.

3. 양방향 LSTM

앞에서 언급한 LSTM의 한계점에 대한 해결책으로 제안된 것이 양방향 RNN이다[16]. 양방향 RNN의 구조는 Fig. 2(a)에 나타낸 것처럼 일반적인 RNN과는 다르게 순방향 은닉층과 추가적으로 역방향 은닉층이 연결된 구조를 가진다. 순방향과 역방향 두 가지의 값을 합치면 완전한 t 시점의 은닉층 값인 h_t 가 된다. 또한, 양방향 RNN의 은닉층에 있는 각각의 뉴런을 LSTM으로 설계하게 되면 아래 Fig. 2(b)에 나타낸 양방향 LSTM 구조로 확장시킬 수 있다. 이러한 양방향 LSTM은 RNN의 문제점인 장기의존성의 문제점을 해결하며 일반적인 LSTM의 한계점인 최근 타임스텝에 강하게 영향을 받는 문제점 또한 해결 할 수 있다[17].

본 논문에서는 앞서 살펴본 방법들의 문제점들을 모두 해결한 양방향 LSTM을 이용하여 미래의 특허출원수를 예측하고 예측된 데이터를 Bass 모델을 이용한 예측데이터와 비교 실험하여 성능을 평가하고자 한다.

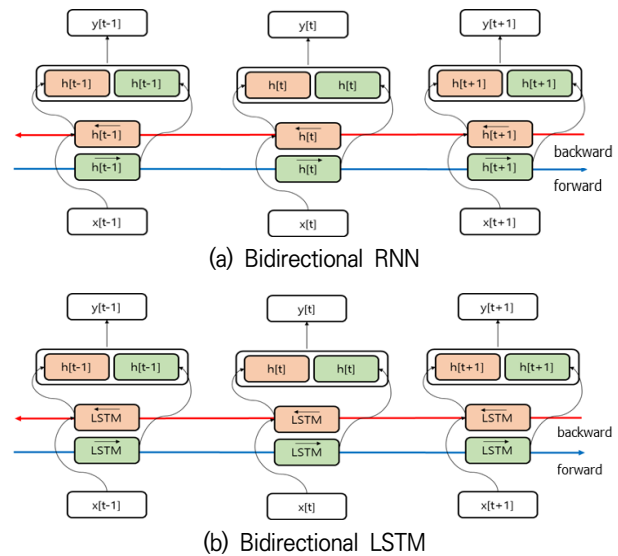


Fig. 2. Bidirectional RNN and Bidirectional LSTM architecture.

그림 2. 양방향 RNN과 양방향 LSTM 구조

III. 실험

1. 데이터셋 구성

기존의 방법인 Bass 모형의 문제점 중 하나인 특허출원수만을 이용하여 예측하기 때문에 다른 요소를 고려하지 못한다는 점을 해결하기 위하여 특허출원수 이외의 고려할 수 있는 다른 요소를 추가하여 데이터셋을 구성하고자 한다.

첫 번째 고려할 수 있는 요소는 출원인 정보이다. 출원인은 특허를 출원한 사람이나 단체를 의미하며 출원서마다 하나 이상의 출원인이 있을 수 있다. 이에 따라 당해 연도의 출원인 수가 증가하면 특허출원수 또한 증가하며, 출원인 수가 감소하면 특허출원수 또한 감소하게 된다.

두 번째 요소는 발명인 정보이다. 발명인은 발명을 완성한 사람을 뜻하며 자연인만이 될 수 있다. 발명인이 증가하면 특허출원수 또한 증가하고, 발명인이 감소하면 특허출원수 또한 감소한다.

세 번째 요소는 CPC(Cooperative Patent Classification) 분류코드이다. CPC 분류코드는 미국과 유럽의 내부분류 체계로서 2013년에 제정된 특허분류 체계이다. CPC분류 코드는 가장 최근에 만들어진 특허분류체계로 다양한 신규 기술에 대해서도 분류코드가 반영되어 있으며 약 27만개의 코드를 갖고 있다. 당해연도에 이러한 CPC코드가 증가하면 특허출원수가 증가하고, CPC코드가 감소하면 특허출원수 또한 감소한다.

위와 같은 내용을 바탕으로 본 논문의 실험에 사용된

학습데이터는 산업부 25대 전략투자 기술분야의 일부인 전기구동 자동차, 자율주행 자동차, 고기능 무인기, 인간 친화형 서비스로봇, 디지털 헬스케어 총 5개의 기술분야에 대하여 한국, 미국, 유럽, 중국, 일본의 1999년~2018년까지의 특허데이터 총 888,134개의 데이터를 사용하였으며 주식회사 테크디엔에이로부터 제공 받은 데이터이다. 미가공 데이터(raw data)의 경우 기술코드, 기술분야, 특허번호, 출원날짜, 특허제목, 특허의 ipc코드, 기재번호, 기재날짜, 출원인명, 국가코드, 발명인명, 특허의 cpc코드로 구성되어있으며 해당 데이터를 가공하여 최종 데이터셋으로 구성하였다.

최종 데이터 셋은 Bass 모형과 동일한 조건에서 실험을 진행하기 위하여 특허출원수만을 갖는 데이터셋과, 여러 가지 요소를 고려 하여 예측하는데 사용하는 데이터셋 두 가지로 구성 하였다.

단 변수 입력 LSTM의 학습데이터 가공하는 단계는 아래와 같다.

1. 기술 코드를 이용하여 5개의 기술 분야에 대한 데이터를 구분한다.
2. 각각의 기술 분야에 대하여 월별 특허출원수를 카운트한다.
3. 총 20년의 데이터를 학습데이터와 검증데이터로 구분 한다.
4. 이후 학습데이터와 검증데이터를 각각 12개월 분량의 입력데이터와 그에 대한 다음 1개월의 정답데이터로 구성된 형식으로 최종데이터 셋을 구성한다.

다변수 입력 LSTM의 학습데이터 가공하는 단계는 아래와 같다.

1. 기술 코드를 이용하여 5개의 기술 분야에 대한 데이터를 구분한다.
2. 각각의 기술분야에 대하여 월별 특허출원수, 출원인수, 발명자수, CPC 분류코드수를 카운트한다.
3. 총 20년의 데이터를 학습데이터와 검증데이터로 구분 한다.
4. 이후 학습데이터와 검증데이터를 각각의 특징들에 대하여 12개월 분량의 총 48개의 입력데이터와 그에 대한 다음 1개월치의 정답데이터 4개로 구성된 형식으로 최종데이터 셋을 구성한다.

2. 실험 환경

본 논문의 실험은 아래 Table 1과 같은 환경에서 진행되었으며, 실험을 위해 총 20년(1999년~2018년) 분량의 데이터를 9:1 비율로 학습데이터와 검증데이터로

각각 나누어 입력으로 하였고, 실험에 사용된 하이퍼파라미터는 아래 Table 2와 같은 구성으로 실험을 진행하였다.

Table 1. Computer Specification.

표 1. 컴퓨터 사양

CPU	Intel(R) Core(TM) i5-8500 3.00GHz
Memory	8GB DDR PC4-21300 X 2
Graphic Card	NVIDIA GeForce GTX 1060 3GB
OS	Microsoft Window10
Tool	Keras (The Python deep learning API)

Table 2. Hyperparameter values.

표 2. 하이퍼파라미터 설정값

Hyperparameter	value
Number of epochs to train	500
Number of LSTM unit	32
Batch size	10
Optimization function	adam
Activation function	tanh

3. 실험 방법 및 평가 방법

위와 같은 내용으로 구성된 파라미터와, 데이터셋을 이용하여 Bass 모형과, 양방향 LSTM을 이용한 특허출원수 예측실험을 진행하였다. 실험에 사용된 네트워크는 입력계층은 12개로 구성되어 있으며 20개의 LSTM 셀로 구성된 은닉계층과 주가 예측을 위한 1개 출력계층으로 이루어진다. 딥러닝의 최적화 함수로 아담(Adam)을 이용하였고, 활성화 함수로는 ReLU 함수를 사용하였다.

먼저 양방향 LSTM을 이용한 학습이 반복되면서 이전의 결과보다 Loss값이 낮게 나온 모델을 계속해서 저장한다. 이후 저장된 각각의 모델들을 이용하여 특허출원수를 예측한 값과 검증데이터를 비교하여 평균 제곱근 오차(RMSE)값을 계산하고, 결과적으로 평균적으로 낮은 제곱근 오차값을 갖는 학습데이터/검증데이터 비율을 찾아보고 이때의 학습데이터와 검증데이터를 이용한 학습 모델을 미래의 특허출원수를 예측하는데 사용한다. 식(1)은 RMSE의 식을 나타낸다.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (p_i - y_i)^2} \quad (1)$$

위와 같은 과정의 결과로 선정된 모델을 이용하여

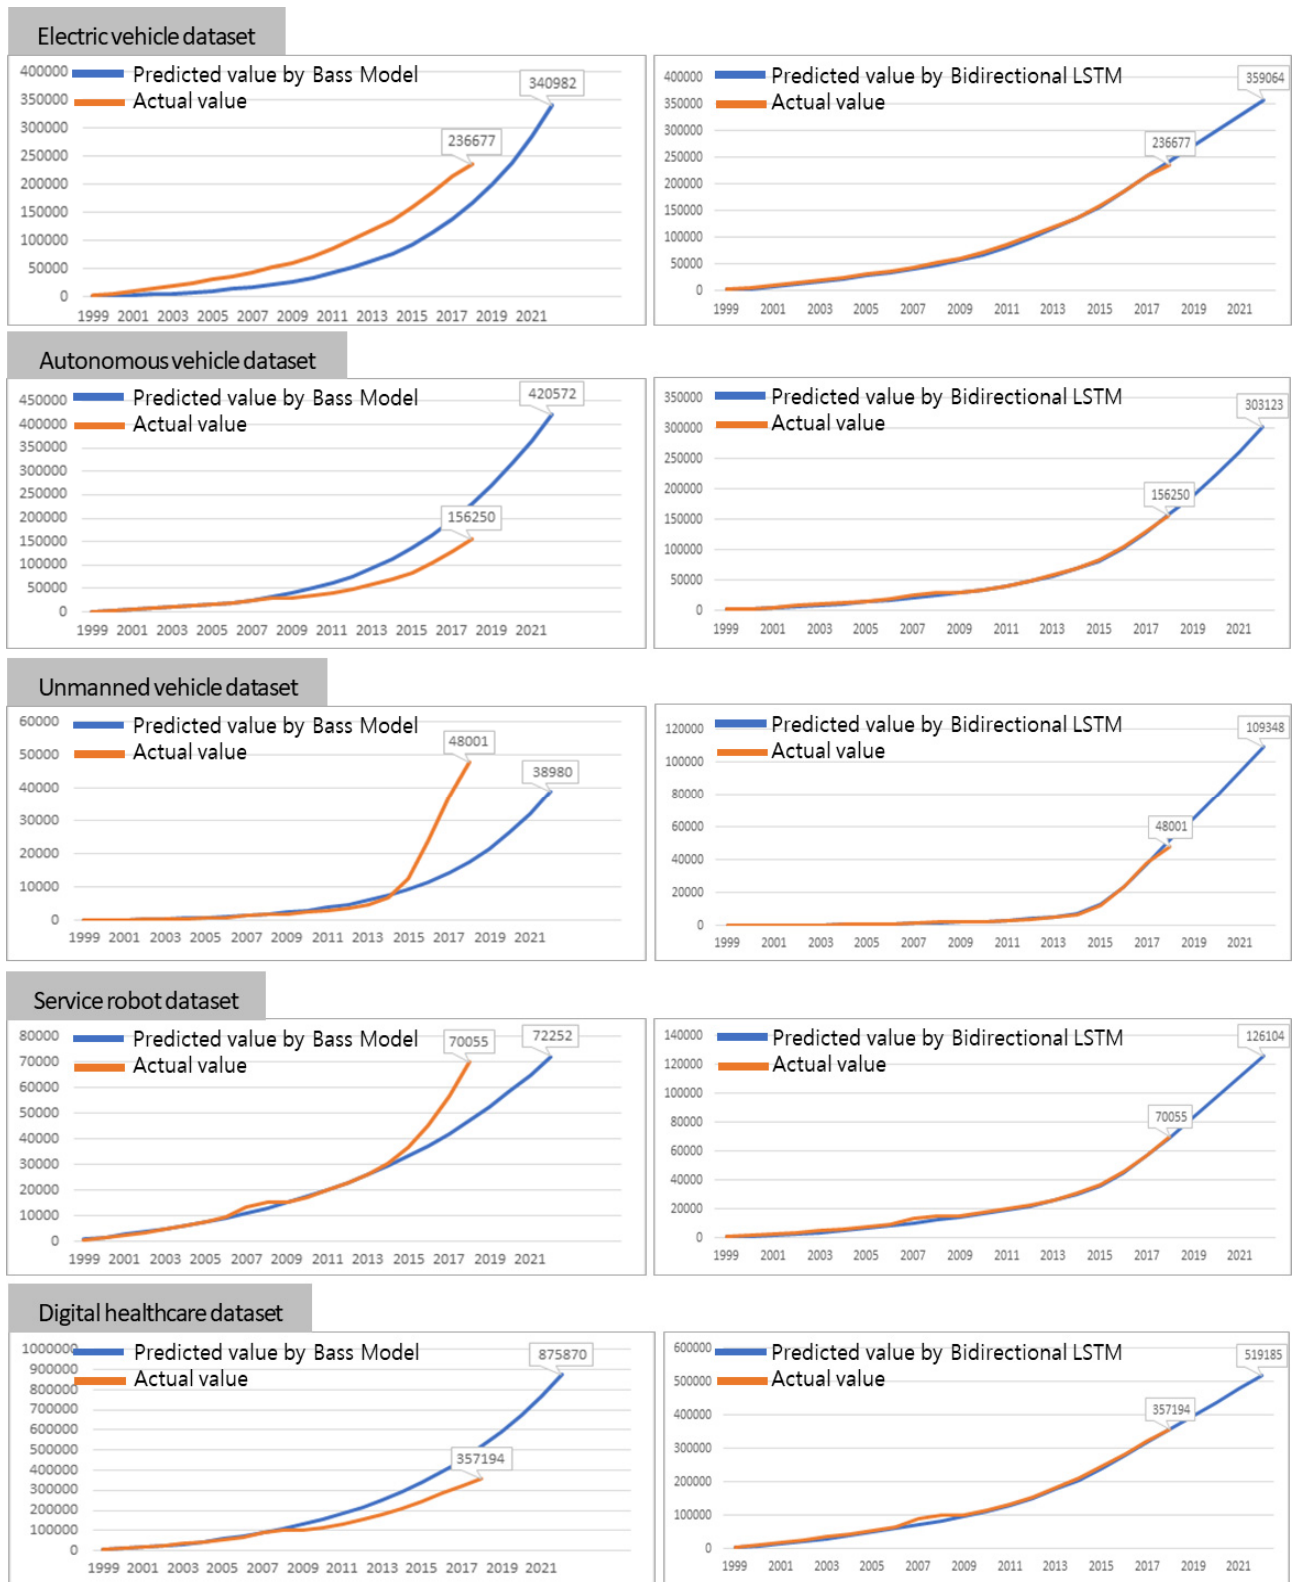


Fig. 3. Experimental results. Graph of actual value and predicted value by Bass model and bidirectional LSTM.

그림 3. 실험 결과. 좌측은 Bass 모델로 예측한 결과이고, 우측은 양방향 LSTM 모델로 예측한 결과임.

2022년까지의 특허출원수를 예측하고 이를 기존의 방법인 Bass모형을 이용한 예측과 비교하여 성능을 평가한다. 평가에 사용되는 방법은 평균 절대 백분율 오차

(Mean Absolute percentage error : MAPE)를 사용하며, 이 방법은 시계열 자료에서 적합도 측정에 주로 사용되는 방법이다. 식(2)은 평균 백분율 오차에 대한 수식을

나타낸다.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \quad (2)$$

위의 식에서 A_t 는 실제 데이터값이며, F_t 는 예측된 값이다. 즉 실제 데이터와 예측치가 가까울수록 MAPE 값은 작아진다. 일반적으로 $0 < MAPE < 10\%$ 이면 매우 우수한 예측모형이라고 판정하며, $10\% < MAPE < 20\%$ 이면 비교적 정확한 예측, $20\% < MAPE < 50\%$ 이면 비교적 합리적인 예측이라고 판정한다[19].

4. 실험 결과

위와 같은 과정을 거쳐 실험한 결과는 Fig. 3과 같다. x축은 연도를 나타내며 y축은 누적 특허출원수이다. 2018년까지의 실제 누적 특허출원수와 2022년까지 예측한 누적 특허출원수에 대한 그래프이다. 위쪽 그래프는 Bass 모형을 사용한 예측결과이고 아래쪽 그래프는 양방향 LSTM을 이용한 예측결과이다. Bass 모형을 이용한 예측보다 양방향 LSTM을 이용한 예측이 더 정확한 것을 확인할 수 있으며, Table 3은 Bass 모형과 양방향 LSTM의 모델 평가에 대한 MAPE 값을 정리한 것이며 이를 확인하였을 때 양방향 LSTM을 이용한 예측이 대략 평균적으로 대략 16% 이상 높은 성능을 보이는 것을 확인할 수 있다.

두 번째 실험은 양방향 LSTM에 특허출원수만 입력값으로 사용하여 특허출원수 예측 결과와 특허출원수, 출원인수, 발명인수, CPC분류코드 총 4가지 특징을 입력값으로 사용한 특허출원수 예측 결과를 비교하였다. 다변수 입력 LSTM을 이용한 특허출원수 예측은 단변수 입력 LSTM과 마찬가지로 학습결과 나온 여러 모델을 이용한 2017, 2018년도 월별 특허출원수 예측값과 2017, 2018년도의 실제 데이터값 사이의 RMSR 값이 가장 낮은 모델을 사용하여 2022년까지의 월별 특허출원수를 예측한다. 다변수 입력 LSTM의 학습 모델을 이용한 2022년까지의 예측데이터를 이용하여 다변수 입력 LSTM의 학습 모델의 적합도를 MAPE를 이용하여 평가할 수 있다. Table 3은 5개 기술분야에 대한 MAPE를 계산하여 정리한 것이며, 전기구동 자동차, 무인 자동차, 인간친화형 서비스로봇, 디지털헬스케어 분야는 각각 5.98%, 5.93%, 8.51%로 매우 우수한 예측 모형이라고 판정할 수 있으며, 자율 주행자동차는 15.34%로 비교적 정확한 예측 모형이라고 판정할 수 있다.

Table 3. Comparison results between Bass model and bidirectional LSTM model.

표 3. Bass 모형과 양방향 LSTM 모델의 성능 비교 결과

dataset	MAPE of Bass model	MAPE of Bidirectional LSTM model (single input)	MAPE of Bidirectional LSTM model (multi input)
Electric vehicle	44.40%	8.75%	5.98%
Autonomous vehicle	27.62%	8.21%	15.34%
Unmanned vehicle	22.5%	8.25%	5.93%
Service robot	20.3%	10.79%	8.51%
Digital healthcare	10.8%	9.57%	9.13%
average	25.12%	9.11%	8.97%

IV. 결론

본 논문에서는 기존의 R&D 선발과정에서 전문가가 참고할 수 있는 자료 중 하나인 Bass 모형을 이용한 향후 발전 방향 예측 정보에 대한 문제점들을 해결하고자 하였고, 인공지능 네트워크 중 양방향 LSTM 네트워크를 제안하였다. 제안한 양방향 LSTM을 보다 정확하게 예측하기 위하여 여러 학습 모델 중 RMSE가 가장 낮은 최적화 모델을 찾아 비교실험의 모델로 사용하였고, 비교실험의 결과 기존에 사용되던 Bass 모형을 이용하여 예측한 결과보다 다변수 입력 양방향 LSTM을 이용하여 학습한 모델을 이용하여 예측한 값의 MAPE 값이 Bass 모형의 MAPE값 보다 평균적으로 16%가량 낮은 수치를 보여주었다. 결론적으로 기존에 사용되던 Bass 모형을 이용한 예측의 결과보다 LSTM을 이용한 예측의 결과가 더욱 신뢰할 수 있는 예측데이터라고 할 수 있다. 따라서 LSTM 네트워크를 이용하여 특허출원수를 예측하는 방법은 기존의 Bass모형을 이용한 방법을 대체가능하며, LSTM을 모델을 이용하여 예측된 특허출원수 데이터를 R&D 과제 선발과정에 분석 데이터로 이용한다면 보다 효율적인 결과를 얻을 수 있을 것이다.

References

[1] R. Haupt, M. Kloyer and M. Lange, "Patent indicators for the technology life cycle development," *Research Policy*, vol.36, no.3, pp.387-398, 2007. DOI: 10.1016/j.respol.2006.12.004.
 [2] C.-Y. Liu and J.-C. Wang, "Forecasting the development of the biped robot walking technique

- in Japan through S-curve model analysis,” *Scientometrics*, vol.82, no.1, pp.21-36, 2010.
DOI: 10.1007/s11192-009-0055-5
- [3] P. Hingley and M. Nicolas, “Methods for forecasting numbers of patent applications at the European Patent Office,” *World Patent Information*, vol.26, no.3, pp.191-204, 2004.
DOI: 10.1016/j.wpi.2003.12.006.
- [4] DH. Kim, SS. Park, YG. Shin and DS. Jang, “Forecasting the Diffusion of Technology using Patent Information: Focused on Information Security Technology for Network-Centric Warfare,” *Journal of the Korea Contents Association*, vol.9, no.2, pp.125-132, 2009. DOI: 10.5392/JKCA.2009.9.2.125
- [5] J. Hong, T. Kim and H. Koo, “A Parameter Estimation of Bass Diffusion Model by the Hybrid of NLS and OLS,” *Journal of the Korean Institute of Industrial Engineers*, vol.37, no.1, pp.74-82, 2011.
- [6] GJ. Kim, DH. Yoon, JH. Hwang and DJ. Sun. “Discovering the emerging technologies through patent topic modeling and growth curve model,” *Journal of Korean Institute of Intelligent Systems*, vol.27, no.4, pp.357-363, 2017.
- [7] D. Nam and G. Choi, “Technology Trend Analysis in the Automotive Semiconductor Industry using Topic Model and Patent Analysis,” *Journal of Korea Technology Innovation Society*, vol.21, no.3, pp.1155-1178, 2018.
- [8] M. N. Kyebambe, G. Cheng, Y. Huang, C. He, and Z. Zhang. “Forecasting emerging technologies: A supervised learning approach through patent analysis,” *Technological Forecasting and Social Change*, vol.125, pp.236-244, 2017.
DOI: 10.1016/j.techfore.2017.08.002.
- [9] R. Dutt, P. Rathi, and V. Krishna, “Novel mixed-encoding for forecasting patent grant duration,” *World Patent Information*, vol.64, pp.102007, 2021. DOI: 10.1016/j.wpi.2020.102007.
- [10] G. Kim and J. Bae. “A novel approach to forecast promising technology through patent analysis,” *Technological Forecasting and Social Change*, vol.117, pp.228-237, 2017.
DOI:10.1016/j.techfore.2016.11.023.
- [11] J. H. Cho, J. Lee, and S. Y. Sohn, “Predicting future technological convergence patterns based on machine learning using link prediction,” *Scientometrics*, vol.126, pp.5413-429, 2021.
DOI: 10.1007/s11192-021-03999-8
- [12] C. L. Giles, G. M. Kuhn and R. J. Williams, “Dynamic recurrent neural networks: Theory and applications,” *IEEE Transactions on Neural Networks*, vol.5, no.2, pp.153-156,
DOI: 10.1109/TNN.1994.8753425.
- [13] S. Hochreiter and J. Schmidhuber “Long Short-Term Memory,” *Neural Computation*, vol.9, no.8, pp.1735-1780, 1997.
DOI: 10.1162/neco.1997.9.8.1735
- [14] Y. Bengio, P. Simard and P. Frasconi, “Learning long-term dependencies with gradient descent is difficult,” *IEEE Transactions on Neural Networks*, vol.5, no.2, pp.157-166, 1994.
DOI: 10.1109/72.279181.
- [15] A. Sherstinsky, “Fundamentals of Recurrent Neural Network(RNN) and Long Short-Term Memory(LSTM) network,” *Physica D: Nonlinear Phenomena*, vol.404, pp.132306, 2020.
DOI: 10.1016/j.physd.2019.132306.
- [16] M. Schuster and K. K. Paliwal, “Bidirectional recurrent neural networks,” *IEEE Transactions on Signal Processing*, vo.45, no.11, pp.2673-2681. 1997. DOI: 10.1109/78.650093.
- [17] H. Sak, A. Senior and F. Beaufays, “Long short-term memory recurrent neural network architectures for large scale acoustic modeling,” *International Speech Communication Association (INTERSPEECH)*. pp.338-342, 2014.
- [18] C. Olah, “Understanding LSTM Networks,” <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- [19] D. Lee, “Exploratory research on the analysis of national R&D programs using growth model,” *Korea Institute of Science and Technology Evaluation and Planning*, vol.27, 2014.
DOI: 10.23000/TRKO201400012780

BIOGRAPHY

Seungwan Choi (Member)

2018 : BS degree in Electronic Engineering, Hanbat National University
2020 : MS degree in Electronic Engineering, Hanbat National University
2020~present : Research Engineer, R&D Team, Saeron S&I

Kwangsoo Kim (Member)

2004 : Ph.D. degree in Electrical Engineering, Seoul National University
2004~2007 : Research Engineer, Samsung Electronics
2007~2008 : Manager, Hyundai Motor Company

2008~present : Professor, Department of Electronic Engineering, Hanbat National University

Sooyeong Kwak (Member)

2010 : PhD degree in Computer Science, Yonsei University.
2010~2011 : Research Engineer, Samsung Electronics.
2011~present : Professor, Department of Electronic Engineering, Hanbat National University