

논문 2022-59-1-3

특허문서의 상세한 설명을 이용한 특허 자동분류에 1D-Convolutional Layer를 적용한 모델의 성능비교

(Comparison of Performance of Models Applying 1D-convolutional Layer to Automatic Patent Classification using Detailed Descriptions of Patent Documents)

김 성 훈*, 김 승 천**

(Sunghoon Kim and Seungcheon Kim[Ⓢ])

요 약

사용자 정의 클래스를 이용한 특허분류에 있어서 특허분류 관점에 따라 특허의 상세한 설명이 분류 관점에 중요한 역할을 하는 경우가 있다. 이러한 특허분류를 순환신경망을 사용해서 자동분류를 한다면 상세한 설명의 긴 길이로 인해 좋은 성능을 내지 못하는 경우가 발생한다. 이러한 긴 시퀀스를 가진 데이터를 분류에 적용하는 방법으로 1D Convolutional Layer를 이용해서 긴 시퀀스를 줄인 후 순환신경망에 적용하거나 1D Convolutional Layer만을 사용하는 모델을 이용하는 방법이 있다. 본 연구에서는 특허 문서의 상세한 설명을 이용해서 특허 분류의 성능을 측정하고자 한다. 기존의 순환신경망인 LSTM 모델, 1D Convolutional Layer를 거친 후 LSTM 모델에 적용하는 방법(1D Conv. LSTM), 그리고 1D Convolutional Layer 만을 사용하는 WaveNet을 사용하는 모델을 정의하였다. 시퀀스의 길이가 6,000이상인 3가지의 특허 데이터셋의 분류 성능을 3가지 모델에 적용하여 정확도를 비교하였다. WaveNet이 3가지 데이터셋에 대해서 가장 높은 정확도를 보였고, LSTM이 가장 낮은 정확도를 보였다. WaveNet은 다른 두 모델에 비해 검증 손실에서도 안정적인 추이를 보였다. 데이터셋 #1에서 WaveNet은 1D Conv. LSTM 에 비해 14.5%, LSTM에 비해 17% 높은 정확도를 기록하였다. 데이터셋 #2에서 WaveNet은 1D Conv. LSTM 에 비해 3.1%, LSTM에 비해 9.8% 높은 정확도를 기록하였다. 데이터셋 #3에서 WaveNet과 1D Conv. LSTM 은 동일한 정확도를 기록하였고, LSTM에 비해 7.3% 높은 정확도를 기록하였다. 특허의 상세한 설명을 이용해서 만들어진 특허의 사용자 정의 클래스를 분류하는 경우 WaveNet은 기존의 순환신경망에 비해 적합한 모델이라고 판단된다.

Abstract

In patent classification using user-defined classes, the detailed description of a patent sometimes plays an important role in the classification point of view depending on the patent classification point of view. If such patent classification is automatically classified using a recurrent neural network, good performance may not be achieved due to the long length of the detailed description. As a method of applying the data having such a long sequence to classification, there is a method of reducing the long sequence by using a 1D convolutional layer and then applying it to a recurrent neural network or using a model using only the 1D convolutional layer. In this study, we intend to measure the performance of patent classification using detailed descriptions of patent documents. The existing LSTM model, which is a recurrent neural network, a method applied to the LSTM model after going through 1D convolutional layer (1D Conv. LSTM), and a model using WaveNet using only 1D convolutional layer were defined. The classification performance of three patent datasets with a sequence length of 6,000 or more was applied to three models to compare the accuracy. WaveNet showed the highest accuracy for the three datasets, and LSTM showed the lowest accuracy. WaveNet showed a stable trend in verification loss compared to the other two models. In dataset #1, WaveNet uses 1D Conv. Accuracy was recorded 14.5% higher than LSTM and 17% higher than LSTM. In dataset #2, WaveNet uses 1D Conv. The accuracy was 3.1% higher than that of LSTM and 9.8% higher than that of LSTM. WaveNet and 1D Conv. LSTM recorded the same accuracy, and 7.3% higher accuracy than LSTM. When classifying user-defined classes of patents made using detailed descriptions of patents, WaveNet is judged to be a more suitable model compared to the existing recurrent neural network.

Keywords : 1D convolutional layer, Patent classification, WaveNet, LSTM

*학생회원, **평생회원, 한성대학교 스마트융합컨설팅학과(Department of Smart Convergence Consulting Hansung University)

Ⓢ Corresponding Author(E-mail : kimsc@hansung.ac.kr)

※ 본 연구는 한성대학교 교내학술연구비 지원과제임.

Received : September 26, 2021

Revised : November 10, 2021

Accepted : November 23, 2021

I. 서 론

기술 혁신에 대한 권리를 보호하는 특성을 가진 특허는 대부분의 기업에서 중요한 자산으로 간주된다. 특허는 또한 기술 발전과 다양화를 대표할 수 있는 충분한 소스를 제공하기 때문에 기술 및 혁신 확산에 중요한 역할을 한다^[1].

특허문서 분류는 특허문서를 효율적으로 검색, 분석, 구조화하기 위해 특허문서를 미리 정의된 클래스로 할당하는 작업이다. 특허문서 클래스는 IPC(International Patent Classification), CPC(Cooperative Patent Classification) 등의 공식적인 클래스와 각 조직 및 개인의 필요에 의해 생성되는 사용자 정의 클래스로 나눌 수 있다.

IPC, CPC 등의 공식적인 클래스는 일반적으로 특허문서가 공개될 때 각국 특허청에 의해서 부여된다. 이러한 공식적인 클래스는 특허의 검색, 분석 등의 작업에 사용된다. 현재 대부분의 공식적 클래스는 특허 전문가에 의해 수작업으로 분류된다.

사용자 정의 클래스는 공식적인 클래스와는 다른 관점에서의 클래스가 필요할 경우 사용목적에 따라 도메인 전문가들에 의해서 클래스가 설계되고 관심 특허가 분류되어 진다. 이러한 사용자 정의 클래스와 클래스에 할당된 특허문서를 바탕으로 경쟁사 특허분석, 기술 동향 분석 등을 수행한다. 대부분의 분류 작업은 특허분류 전문가에 의해 수작업으로 진행되고 있으므로 많은 시간과 비용이 소요된다. 이러한 비용과 시간을 절약하기 위해, 전문가에 의해 분류된 특허 데이터를 학습 데이터로 사용하여 생성된 지도학습 특허문서 자동분류기는 좋은 해결책이 될 수 있다. 이러한 이유로 특허문서 자동분류에 대한 많은 연구가 진행되었다.

Shaobo Li, 등은 특허분류를 위해 CNN(Convolutional Neural Network)과 word vector embedding에 기반한 딥러닝 알고리즘(Deep Patent)을 발표하였다^[2]. 또한 Chi-Hung Wu, 등은 유전기 기반한 지원 벡터머신(HGA-WVM)을 기반으로 반도체 장비 부품에 대해 234개의 특허문서가 포함된 전문가에 의해 분류된 분류 기반으로 특허문서를 분리하였다^[3].

Jieh-Sheng Lee 등은 Pre-trained BERT model을 이용해서 특허를 분류하였고 이를 Deep Patent와 결과를 비교하여 분류 성능 향상을 이루었음을 보고하였다^[4].

이러한 연구들의 대부분은 특허문서의 구성요소 중 제목, 요약 또는 청구항을 사용해서 특허분류를 수행하였으

며 특허문서의 구성요소 중 가장 많은 부분을 차지하는 특허의 상세한 설명은 입력데이터로 사용되지 않았다.

여러 연구에서 특허의 상세한 설명이 입력데이터로 사용되지 않은 이유는 다음과 같이 유추할 수 있다.

첫째, 연구에 사용된 특허의 분류 체계가 상세한 설명이 필요하지 않은 분류 체계이다. 연구에 사용된 IPC 등의 공식적인 클래스는 제목, 요약, 청구항만으로 분류가 가능하다고 판단한 것으로 보인다. 공식적 클래스들은 기술 분야에 대한 분류로 이루어져있으므로 상세한 설명을 제외하더라도 분류할 수 있을 것으로 판단한 것으로 보인다. 실제로 특허의 상세한 설명에는 배경기술, 해결과제 및 발명의 효과 등이 포함되어 있어서 공식적 클래스를 판단하는데 필요하지 않은 내용들이 다수 포함되어 있다.

둘째, 상세설명과 같은 길이가 긴 텍스트를 연구에 사용된 모델에 적용하게 되면 오히려 분류 성능이 나빠졌으리라 예상된다. 제목, 요약을 토큰으로 분리했을 때 100 ~ 200개의 토큰이라 한다면 상세한 설명을 토큰으로 나누면 4,000 ~ 12,000 토큰 정도로 나뉘지는 경우가 대부분이다. 이러한 긴 토큰을 기존의 LSTM^[5] 등의 순환신경망 계열 모델에 적용한다면 기울기 소실과 폭주 문제가 발생하여 분류 성능에 저하를 초래한다.

이러한 원인들로 인해 기존의 연구에서는 상세한 설명을 입력 데이터로 사용하지 않았고 이러한 선택은 공식적 클래스를 분류하는데 더 좋은 선택이었다고 판단된다.

그러나 실제 산업현장에서는 특허의 공식적인 클래스도 많이 사용되지만 사용자 정의 클래스도 많이 사용된다. 이러한 사용자 정의 클래스는 산업별로 또는 기업별로 각각의 목적에 따라 다양한 분류 기준에 맞게 정의된다.

만약 특정 사용자 정의 클래스의 분류기준이 상세한 설명에 기초한 내용으로 정의된다면 제목, 요약만으로는 해당 기준에 부합하는 특허 자동분류를 수행하기 힘들다. 또한 상세한 설명을 기존의 순환신경망 계열의 모델에 적용한다면 긴 시퀀스로 인해 기울기 소실 및 폭주 문제로 인해 분류 정확도의 성능이 저하될 것이다.

본 연구에서는 이러한 문제를 해결하기 위해 1D-Convolutional Layer와 LSTM을 결합한 모델을 이용하여 상세한 설명을 입력 데이터로 사용해서 특허 자동분류를 수행했을 때의 성능을 측정하였다.

또한 긴 시퀀스의 하나인 음성 데이터의 처리를 목적으로 1D-Convolutional Layer만으로 구성된 WaveNet^[6]이 제안되었는데 이를 특허의 상세한 설명과 같이 긴 자연어 처리를 수행할 수 있도록 변형하여 특허 자동분류를 수행하였고 이에 대한 성능을 측정하였다.

본 연구에서는 3가지의 데이터셋을 사용하여 기존의 LSTM 모델의 결과와 제안된 2가지 모델(1D-Convolutional Layer + LSTM, WaveNet)을 비교하여 성능을 비교하였다.

II. 본 론

1. 순환 신경망에 상세한 설명 적용의 문제

대다수 특허의 상세한 설명은 4,000개 이상의 단어로 이루어졌고 수 만개의 단어로 이루어진 특허도 존재한다. 긴 길이의 상세한 설명을 순환신경망에 적용한다면 4,000개 이상의 시퀀스 데이터로 변환되고 이를 순환신경망에 적용한다면 기울기 소실과 폭주 문제를 가질 수 있다. 또한 모델을 훈련하는 시간이 오래 걸리며 훈련이 불안정하여 오차가 크게 증가할 수 있다.

순환신경망의 단기 기억문제를 해소할 수 있다고 보고된 LSTM 모델에서도 특허의 상세한 설명이 가진 수천의 길이를 가진 시퀀스를 처리하는데 문제가 발생할 수 있다.

2. 1D-Convolutional Layer 와 LSTM 결합 모델

긴 시퀀스로 인해 발생하는 기울기 소실 등의 문제를 해결하기 위해서는 시퀀스 데이터를 특성을 최대한 유지하면서 길이를 줄인 후 LSTM을 통과시킨다면 LSTM 자체에서 발생하는 기울기 소실 문제를 줄일 수 있다.

본 연구에서 데이터의 특성을 유지하면서 길이를 줄이는 방법으로 1D-Convolutional Layer를 중첩하여 사용하여 시퀀스 데이터의 길이를 축소시킨 후, 줄여진 시퀀스를 LSTM에 통과하는 모델을 생성하였다.

그림 1은 1D-Convolutional Layer 와 LSTM 결합 모델의 예를 보여준다. 해당 모델에 총 6,053개의 시퀀스 데이터가 입력된다, 즉 훈련 데이터를 구성하는 특허데이터의 상세설명 최대 길이가 6,053 이다. 입력된 데이터는 3개의 1D-Convolutional Layer를 통과하게 된다. 1개의 1D-Convolutional Layer를 통과하면 시퀀스의 길이는 반으로 줄어들게 된다. 총 3개의 층을 통과하므로 최초 6,053의 길이를 가진 시퀀스 데이터가 754의 길이를 가진 시퀀스로 줄어들게 되며 길이가 1/8 로 줄어든 시퀀스 데이터가 LSTM 층을 통과하게 된다.

3. WaveNet의 변형 모델

긴 시퀀스 데이터의 대표적인 사례로는 텍스트와 음성 데이터가 있다. 음성 데이터를 처리하고 합성하기

Layer (type)	Output Shape	Param #
input_1 (InputLayer)	[(None, 6053)]	0
embedding (Embedding)	(None, 6053, 100)	1075400
conv1d (Conv1D)	(None, 3025, 10)	4010
conv1d_1 (Conv1D)	(None, 1511, 20)	820
conv1d_2 (Conv1D)	(None, 754, 30)	2430
batch_normalization (BatchNo)	(None, 754, 30)	120
elu (ELU)	(None, 754, 30)	0
bidirectional (Bidirectional)	(None, 20)	3280
dense (Dense)	(None, 5)	105
Total params: 1,086,165		
Trainable params: 1,086,105		
Non-trainable params: 60		

그림 1. 1D-Convolutional Layer LSTM 모델 (dataset #1)
Fig. 1. 1D-Convolutional Layer LSTM model (dataset #1).

위해 Aaron van den Oord 등이 발표한 논문에서 WaveNet을 제안하였다^[6].

WaveNet은 층마다 팽창 비율을 두 배로 늘리는 1D-Convolutional Layer를 쌓는다. 첫 번째 층이 한번에 2개의 타임 스텝만을 바라보고, 다음 층은 4개의 타임 스텝을 보고 다음 층은 8개의 타임 스텝을 바라보는 구조이다. 이런 식으로 하위 층은 단기 패턴을 학습하고 상위 층은 장기 패턴을 학습한다. 팽창 비율을 두 배로 늘린 덕분에 네트워크는 아주 긴 시퀀스를 효율적으로 처리할 수 있다고 한다^[6].

본 연구에서는 WaveNet의 음성 합성부분을 제외하고 긴 시퀀스를 학습하는 부분을 이용하여 이를 음성 데이터를 처리하지 않고 텍스트 데이터를 처리하는 구조로 변경하여 모델을 생성하였다.

그림 2는 WaveNet의 변형모델의 예를 보여준다. 해당 모델에 총 6,053개의 시퀀스 데이터가 입력된다, 즉 훈련 데이터를 구성하는 특허데이터의 상세설명 최대 길이가 6,053 이다.

입력데이터가 총 8개의 1D-Convolutional Layer를 통과하게 된다. 해당 Layer들은 팽창비율을 2배로 늘려가게 된다. 첫 번째 층에서는 2개의 스텝을 학습하게 되고 2번째 층에서는 4개의 스텝을 마지막 8번째 층에서는 256개의 스텝을 학습하게 된다.

마지막으로 9번째 1D-Convolutional Layer에서는 클래스의 개수만큼 필터를 지정하고 커널의 크기를 1로 지정하고 마지막으로 Global Average Pooling 1D를 통과시켜서 학습하는 모델이다.

Layer (type)	Output Shape	Param #
embedding (Embedding)	(None, 6053, 100)	1075400
conv1d (Conv1D)	(None, 6053, 20)	4020
conv1d_1 (Conv1D)	(None, 6053, 20)	820
conv1d_2 (Conv1D)	(None, 6053, 20)	820
conv1d_3 (Conv1D)	(None, 6053, 20)	820
conv1d_4 (Conv1D)	(None, 6053, 20)	820
conv1d_5 (Conv1D)	(None, 6053, 20)	820
conv1d_6 (Conv1D)	(None, 6053, 20)	820
conv1d_7 (Conv1D)	(None, 6053, 20)	820
conv1d_8 (Conv1D)	(None, 6053, 5)	105
global_average_pooling1d (G1 (None, 5)		0
Total params: 1,085,265		
Trainable params: 1,085,265		
Non-trainable params: 0		

그림 2. WaveNet 모델 (dataset #1)
Fig. 2. WaveNet model (dataset #1).

1D-Convolutional Layer가 처음에는 짧은 시퀀스의 길이를 학습하고 층이 거듭 될수록 긴 시퀀스의 길이를 학습함으로써 긴 길이의 상세한 설명의 시퀀스 데이터를 효과적으로 학습할 수 있게 된다.

III. 실험

1. 특허 데이터 셋

본 연구에서는 총 3가지 종류의 데이터 셋을 사용하였다. 분류의 신빙성을 확보하기 위해 미국 등록특허의 CPC(Cooperative Patent Classification) 분류 데이터를 사용하였다. CPC는 미국 특허청과 유럽 특허청이 각각 관리하던 분류체계를 통합하여 새롭게 만들어진 분류체계이다^[7].

가. CPC C01 계열 데이터

CPC C01계열 데이터의 클래스는 C01B, C01C, C01D, C01F, C01G 5개의 클래스 데이터를 사용하였다. 각 클래스의 분류기준 및 정의는 미국 특허청과 유럽 특허청의 공동 작업으로 만들어졌으며 새롭게 공개되는 특허들에 대해서도 해당 분류기준에 맞게 정의된다.

CPC C01 계열 데이터를 훈련데이터, 검증데이터 그리고 테스트 데이터로 분리한다. 이를 데이터셋 #1 이라 명명한다. 데이터셋 #1 의 구성은 각 클래스별로 200

건을 사용하였고 전체 1,000건의 특허데이터로 구성하였다. 훈련데이터와 테스트 데이터의 비율은 8:2 로 분리하였으며 분리한 기준은 출원일을 기준으로 하였다. 즉 상대적으로 과거의 데이터를 훈련데이터로 사용하고 최신의 데이터를 테스트데이터로 사용하였다. 이는 실제 특허분류업무에서 이루어지는 과정과 동일하게 이전에 출원된 데이터의 분류를 바탕으로 미래에 출원되는 특허데이터를 분류하는 프로세스와 유사한 환경을 표현하기 위함이다.

나. CPC H01 계열 데이터

CPC H01계열 데이터의 클래스는 H01B, H01C, H01F, H01G, H01H 등 총 14 개의 클래스 데이터를 사용하였다.

CPC H01 계열 데이터를 훈련데이터, 검증데이터 그리고 테스트 데이터로 분리한다. 이를 데이터셋 #2라 명명한다. 데이터셋 #2 의 구성은 각 클래스별로 200 건을 사용하였고 전체 2,800건의 특허데이터로 구성하였다. 훈련데이터와 테스트 데이터의 비율은 8:2 로 분리하였으며 분리한 기준은 출원일을 기준으로 하였다.

다. CPC C01 + H01 데이터

CPC C01 계열과 CPC H01 계열 데이터를 결합하여 총 19개의 클래스 데이터를 사용한다. 이를 데이터셋 #3이라 명명한다. 데이터셋 #3 의 구성은 각 클래스별로 200 건을 사용하였고 전체 3,800건의 특허데이터로 구성하였다. 훈련데이터와 테스트 데이터의 비율은 8:2 로 분리하였으며 분리한 기준은 출원일을 기준으로 하였다.

표 1에서 3가지 데이터셋의 구성에 대한 요약정보를 나타내었다.

표 1. 데이터셋 요약
Table 1. Dataset summary.

	class	train	valid	test	sequence length
Dataset #1	5	720	80	200	6,053
Dataset #2	14	2,016	224	560	6,252
Dataset #3	19	2,736	304	760	6,254

각 데이터셋의 시퀀스 데이터의 길이는 각각 6,053, 6,252 그리고 6,254 이다.

2. 베이스라인 모델

본 연구에서 제안된 2가지 모델의 성능을 비교하기

위해서 LSTM 모델을 베이스라인 모델로 사용하였다.

LSTM 모델을 사용한 이유는 긴 시퀀스를 줄이지 않고 직접 통과하는 모델이므로 긴 시퀀스를 처리하는데 있어 제안된 모델과 비교에 적합할 것으로 판단하였다.

3. 실험방법

준비된 3가지 데이터셋을 이용해서 3가지 모델에 대해 실험을 실시한다. 총 9가지의 경우에 대해서 훈련데이터로 훈련하고 검증데이터를 이용해서 검증데이터의 loss가 가장 적은 에폭의 훈련된 모델을 저장한다. 저장된 모델을 이용해서 테스트 데이터를 예측하고 정답과 비교해 정확도를 측정한다.

표 2. 각 모델의 주요 하이퍼파라미터
Table 2. Hyperparameter of each models.

	LSTM	1D Con. LSTM	WaveNet
Learning Rate	0.001	0.001	0.001
Batch Size	8	8	8
Optimizer	CrossEntropy	CrossEntropy	MSE
LSTM unit	16	16	-
1D-Conv Layer	-	3	8

표 2는 각 모델들의 주요 하이퍼파라미터와 조건들을 보여준다. LSTM 모델은 1D Convolutional Layer를 사용하지 않고 WaveNet은 LSTM unit을 사용하지 않는 특징이 있다.

4. 실험결과

가. 데이터셋 #1의 모델별 정확도

데이터셋 #1 에서 각 모델의 성능을 알아보기 위해 훈련과정에서 훈련데이터의 loss와 검증데이터의 loss를 측정하였고 최종적으로 테스트 데이터의 정확도를 측정하였다.

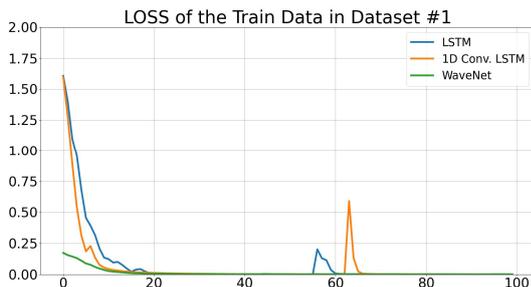


그림 3. 데이터셋 #1의 에폭별 평균적 훈련 손실
Fig. 3. Average training loss per epoch in Dataset #1.

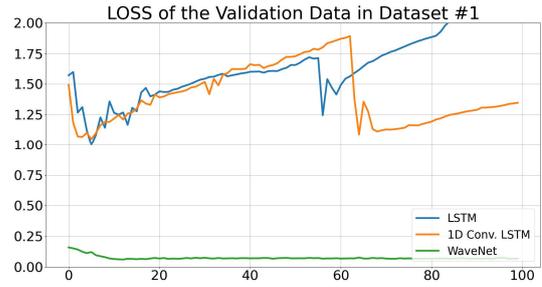


그림 4. 데이터셋 #1의 에폭별 평균적 검증 손실
Fig. 4. Average validation loss per epoch in Dataset #2.

그림 3, 4의 훈련 손실과 검증 손실의 추이를 살펴보면 3개 모델의 훈련 손실은 비교적 안정적으로 감소하고 있으며 WaveNet, 1D Conv. LSTM 그리고 LSTM 순으로 손실의 감소가 이루어진다.

검증 손실은 WaveNet은 14 에폭까지 꾸준히 감소 후 안정적으로 유지되었다. 반면에 1D Conv. LSTM과 LSTM은 5 에폭까지 감소하다 다시 상승하는 추이를 반복한다. 이는 훈련 손실과 달리 검증 손실이 다시 상승하는 것으로 보아 오버피팅이 발생하는 것을 알 수 있으며 이는 안정적으로 훈련되지 않다고 볼 수 있다.

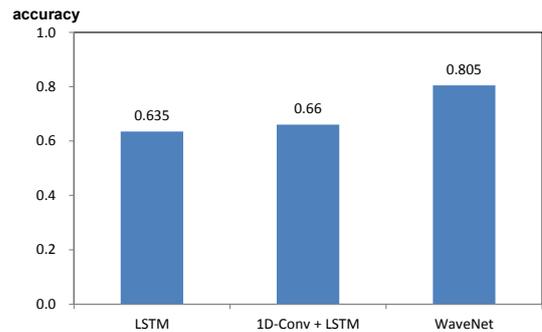


그림 5. 데이터셋 #1 테스트 데이터 정확도
Fig. 5. Test data accuracy of Dataset #1.

그림 5는 최소의 검증 손실의 모델을 이용해서 200건의 테스트 데이터 정확도를 보여준다.

정확도는 WaveNet(0.805) > 1D Conv. LSTM(0.66) > LSTM(0.635)의 순이다.

WaveNet는 1D Conv. LSTM 에 비해 14.5%, LSTM 에 비해 17% 높은 정확도를 기록하였다.

1D Conv. LSTM 이 LSTM에 비해 2.5% 높은 정확도를 기록하였다.

나. 데이터셋 #2의 모델별 정확도

데이터셋 #2에서 각 모델의 성능을 알아보기 위해 훈

련과정에서 훈련데이터의 loss와 검증데이터의 loss를 측정하였고 최종적으로 테스트 데이터의 정확도를 측정하였다.

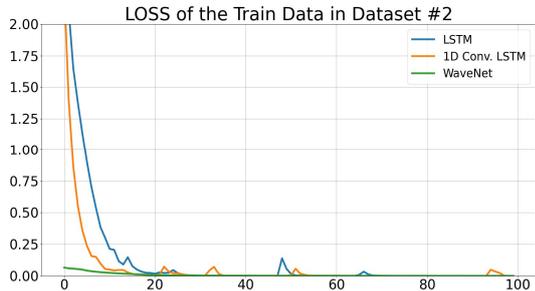


그림 6. 데이터셋 #2의 에폭별 평균적 훈련손실
Fig. 6. Average training loss per epoch in Dataset #2.

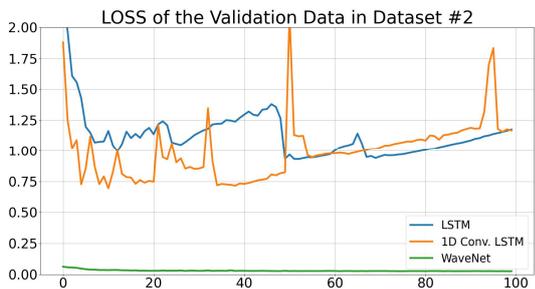


그림 7. 데이터셋 #2의 에폭별 평균적 검증 손실
Fig. 7. Average validation loss per epoch in Dataset #2.

그림 6, 7의 훈련 손실과 검증 손실의 추이를 살펴보면 3개 모델의 훈련 손실은 비교적 안정적으로 감소하고 있으며 WaveNet, 1D Conv. LSTM 그리고 LSTM 순으로 손실의 감소가 이루어진다.

검증 손실은 WaveNet은 5 에폭까지 꾸준히 감소 후 안정적으로 유지되었다. 반면에 1D Conv. LSTM 과 LSTM은 5에폭까지 감소하다 다시 상승하는 추이를 반복한다.

데이터셋 #2에서는 1D Conv. LSTM 이 LSTM에 비해 낮은 검증 손실을 기록하고 있지만, WaveNet에 비해 다른 두 모델은 오버피팅이 발생하고 안정적인 추이를 보이고 있지는 않았다.

그림 8는 최소의 검증 손실의 모델을 이용해서 560건의 테스트 데이터 정확도를 보여준다.

정확도는 WaveNet(0.893) > 1D Conv. LSTM(0.862) > LSTM(0.795)의 순이다.

WaveNet는 1D Conv. LSTM 에 비해 3.1%, LSTM에 비해 9.8% 높은 정확도를 기록하였다.

1D Conv. LSTM 이 LSTM에 비해 6.7% 높은 정확도를 기록하였다.

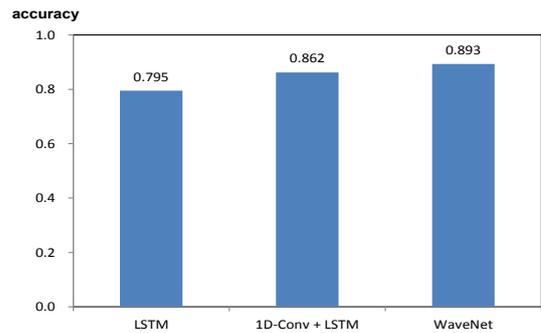


그림 8. 데이터셋 #2 테스트 데이터 정확도
Fig. 8. Test data accuracy of Dataset #2.

다. 데이터셋 #3의 모델별 정확도

데이터셋 #3에서 각 모델의 성능을 알아보기 위해 훈련과정에서 훈련데이터의 loss와 검증데이터의 loss를 측정하였고 최종적으로 테스트 데이터의 정확도를 측정하였다.

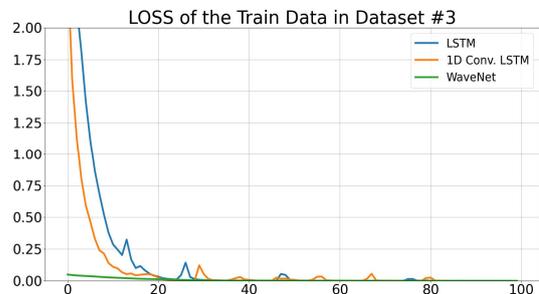


그림 9. 데이터셋 #3의 에폭별 평균적 훈련 손실
Fig. 9. Average training loss per epoch in Dataset #3.

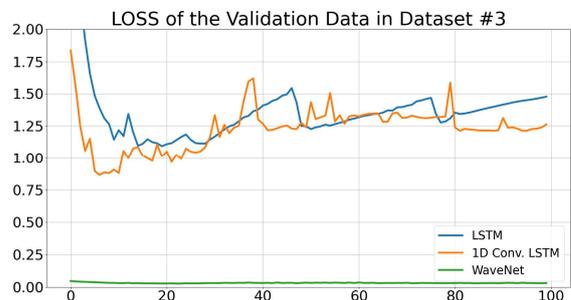


그림 10. 데이터셋 #3의 에폭별 평균적 검증 손실
Fig. 10. Average validation loss per epoch in Dataset #3.

그림 9, 10의 훈련 손실과 검증 손실의 추이를 살펴보면 3개 모델의 훈련 손실은 비교적 안정적으로 감소하고 있으며 WaveNet, 1D Conv. LSTM 그리고 LSTM 순으로 손실의 감소가 이루어진다.

검증 손실은 WaveNet은 5 에폭까지 꾸준히 감소 후 안정적으로 유지되었다. 반면에 1D Conv.

LSTM 과 LSTM은 5 ~8 에폭까지 감소하다 다시 상승하는 추이를 반복한다.

데이터셋 #3 에서는 1D Conv. LSTM 이 LSTM에 비해 낮은 검증 손실을 기록하고 있지만, WaveNet에 비해 다른 두 모델은 오버피팅이 발생하고 안정적인 추이를 보이고 있지는 않았다.

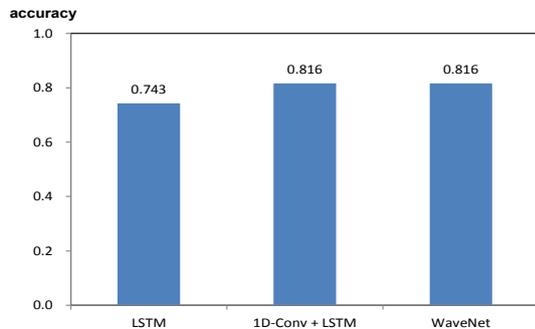


그림 11. 데이터셋 #3 테스트 데이터 정확도
Fig. 11. Test data accuracy of Dataset #3.

그림 11는 최소의 검증 손실의 모델을 이용해서 760건의 테스트 데이터 정확도를 보여준다.

정확도는 WaveNet(0.816) > 1D Conv. LSTM(0.816) > LSTM(0.743)의 순이다.

WaveNet과 1D Conv. LSTM 은 동일한 정확도를 기록하였고, LSTM에 비해 7.3% 높은 정확도를 기록하였다.

IV. 결 론

특허의 상세한 설명은 그 길이의 방대함으로 인해 딥러닝 모델을 이용한 분류에 사용되지 않는 경우가 많았다. 본 연구에서는 상세한 설명과 같은 긴 길이의 시퀀스 데이터를 처리하는 모델을 선정하고 이를 특허 분류에 맞도록 변경하여 3가지 데이터 셋을 이용하여 분류 성능을 측정하였다. 또한 그 결과의 유효성을 판단하기 위하여 LSTM 모델을 베이스라인 모델을 선정하였고 베이스라인 모델도 동일한 데이터셋을 이용하여 성능을 측정하였다. 총 3가지 모델을 3가지 데이터셋을 이용하여 분류 성능을 측정하고 이를 비교하였다.

1D Convolutional Layer로만 구성된 WaveNet은 3가지 모델 중 가장 높은 정확도를 보였으며 훈련 검증과 손실 검증도 안정적으로 유지됨을 확인 하였다. 테스트 데이터의 정확도 또한 다른 2가지 모델에 비해 높게 나타났다.

LSTM 모델은 훈련 손실은 안정적이었으나 검증손실에서는 감소와 증가를 반복하였으며 또한 오버피팅도 높게 발생하였으며, 테스트 데이터의 정확도 또한 다른 두 모델에 비해서 상당히 낮게 나왔다. 6,000 여개의 시퀀스 데이터를 이용해서 LSTM의 모델에서는 낮은 성능을 보임을 알 수 있다.

1D Conv. LSTM 모델은 입력 시퀀스를 1D Convolutional Layer를 통과시켜서 시퀀스의 길이를 줄이고 이 줄여진 시퀀스를 LSTM을 통과시키는 모델이다. 3가지 데이터 셋에서 훈련시켰을 때 훈련 손실은 다른 모델들과 마찬가지로 안정적으로 감소하고 유지되었으나 검증 손실에 있어서는 LSTM과 마찬가지로 감소와 증가를 반복하였다. 테스트 데이터의 정확도는 LSTM에 비해 높게 나타났으나 WaveNet에 비해 낮게 측정되었다.

긴 시퀀스를 가진 특허 데이터의 상세한 설명을 LSTM 등의 순환신경망에 직접 적용하는 것은 정확도와 성능 향상에 한계가 있다. 이는 기존에 알려진 기술기 소실과 발산에 의한 문제가 발생한 것이라고 판단된다. 본 연구에서 제안한 두 가지 모델은 이러한 긴 시퀀스 문제를 해결하기 위해 1D Convolutional Layer를 이용하였다. 두 가지 모델 중 1D Convolutional Layer와 LSTM을 병행해서 사용하는 모델에 비해 1D Convolutional Layer만을 사용하는 WaveNet이 높은 정확도와 성능을 보였다.

특허의 상세한 설명을 이용해서 만들어진 특허의 사용자 정의 클래스를 분류하는 경우 WaveNet의 변형 모델은 기존 순환신경망에 비해 정확도를 개선할 수 있는 모델이라 판단된다.

REFERENCES

- [1] A. J. C. Trappey, F. C. Hsu, C. v. Trappey, and C. I. Lin, "Development of a patent document classification and search platform using a back-propagation network," *Expert Systems with Applications*, vol. 31, no. 4, pp. 755 - 765, Nov. 2006, doi: 10.1016/j.eswa.2006.01.013.
- [2] Shaobo Li, Jie Hu, Yxin Cui, Jianjun Hu., "DeepPatent: patent classification with convolutional neural networks and word embedding" *Scientometrics*(2018) 117:721-744
- [3] Chih-Hung Wu, Ynn Ken, Tao Huang., "Patent classification system using a new hybrid genetic algorithm support vector machine" *Applied Soft*

- Computing Volume10, issue 4(2010)
- [4] Jieh-Sheng Lee, Jieh Hsiang., "Patent Classification by Fine-Tuning BERT Language Model" Word patent Information Volume61, June 2020. 101965
- [5] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," Neural Computation, vol. 9, no. 8, pp. 1735 - 1780, Nov. 1997, doi: 10.1162/neco.1997.9.8.1735.
- [6] A. van den Oord et al., "WaveNet: A Generative Model for Raw Audio", Sep. 2016, [online]. Available: <http://arxiv.org/abs/1609.03499>
- [7] European Patent Office, United States Patent and Trademark office., "Cooperative Patent Classification", [Online]. Available: <https://www.cooperativepatentclassification.org/cpcSchemeAndDefinitions/table>

 저 자 소 개



김 성 훈(학생회원)
 1997년 경희대학교 화학공학과
 학사 졸업(공학사)
 2000년 경희대학교 화학공학과
 석사 졸업(공학석사)
 2018년~현재 한성대학교 스마트
 융합건설링학과 박사 과정

2016년~현재 (주)웍스 서비스개발부 부서장
 <주관심분야: 인공지능, 딥러닝, NLP, 특허분석>



김 승 천(평생회원)
 1994년 2월: 연세대학교 전자공학과
 학사 졸업(공학사).
 1996년 2월: 연세대학교 전자공학과
 석사 졸업(공학석사)
 1999년 8월: 연세대학교 전기컴퓨터
 공학과(공학박사)

2000년 1월~2001년 1월 Univ. of Sydney
 Research Fellow
 2001년 2월~2003년 8월 LG전자 DTV/DA 연구소
 선임 연구원
 2009년 7월~2010년 7월 Univ of Oregon 방문교수
 2003년 3월~현재 한성대학교 IT 융합공학부 교수
 <주관심분야: 네트워크 보안, 블록체인 서비스,
 사물인터넷 보안, 5G 이동통신망 서비스>