

도로포장의 유지관리 계획 수립을 위한 딥러닝 기반 열화 예측 모델 개발

이용준¹ · 선종완¹ · 이민재*

¹한국건설기술연구원 인프라안전연구본부

Development of Deep Learning Based Deterioration Prediction Model for the Maintenance Planning of Highway Pavement

Lee, Yongjun¹, Sun, Jongwan¹, Lee, Minjae*

¹Department of Infrastructure Safety Research, Korea Institute of Civil Engineering and Building Technology

Abstract : The maintenance cost for road pavement is gradually increasing due to the continuous increase in road extension as well as increase in the number of old routes that have passed the public period. As a result, there is a need for a method of minimizing costs through preventative grievance preventive maintenance requires the establishment of a strategic plan through accurate prediction of road pavement. Hence, In this study, the deep neural network(DNN) and the recurrent neural network(RNN) were used in order to develop the expressway pavement damage prediction model. A superior model among these two network models was then suggested by comparing and analyzing their performance. In order to solve the RNN's vanishing gradient problem, the LSTM (Long short-term memory) circuits which are a more complicated form of the RNN structure were used. The learning result showed that the RMSE value of the RNN-LSTM model was 0.102 which was lower than the RMSE value of the DNN model, indicating that the performance of the RNN-LSTM model was superior. In addition, high accuracy of the RNN-LSTM model was verified through the comparison between the estimated average road pavement condition and the actually measured road pavement condition of the target section over time.

Keywords : Pavement Deterioration Prediction, Deep Learning, Recurrent Neural Network, Long Short-Term Memory, Deep Neural Network

1. 서론

1.1 연구의 배경 및 목적

도로연장의 지속적인 증가와 건설 후 공용기간이 상당히 경과한 노후 노선이 늘어남에 따라 도로시설물에 대한 유지관리의 중요성이 점차 강조되고 있다. 특히, 도로 포장은 사용자 입장에서는 승차감, 안전성, 쾌적성 등과 밀접하게 관련되어 있고, 관리자의 입장에서는 보수예산의 상당 부분을 차지함으로 인하여 효율적인 관리가 필수적으로 요구된다. 여기서 효율적 관리란 결국 '최소한의 비용으로 최대한의 효과를 달성'하기 위한 관리방안을 의미하며, 이는 관리연장

증가와 노후화에 비해 상대적으로 제한적인 예산을 적절히 활용하기 위한 전략이 수립되어야 함을 의미한다.

포장 유지관리 전략(계획) 수립을 위해서는 포장의 유지보수 시기 및 공법 결정을 위한 의사결정체계가 필요하며, 이 과정에서 해당 도로구간의 열화 예측이 매우 중요하다. 즉, 과거 및 현재의 포장상태를 기반으로 열화예측을 통한 공용수명의 추정과정은 유지보수가 필요한 구간의 예측과 예산의 추정에 중요한 기초정보로 활용되기 때문이다(Do et al., 2012).

도로포장 분야에서 일반적으로 말하는 열화예측 혹은 파손모형(deterioration model)이란 포장의 열화과정에 대한 해석을 다루는 내용으로 주로 유지보수가 요구되기까지의 기대수명과 그 기대수명 내에서 열화특성의 변화과정을 표현하는 것으로 정의할 수 있다(Kwon et al., 2002).

일반적으로 도로포장의 열화 예측 모델은 회귀분석법, Markov 모델, 신뢰성 기반 모델 등 다양하다(Kobayashi et. al., 2010; Do et al., 2011).

최근 컴퓨터 사양의 급격한 발전과 함께 오픈 소스로 공개

* Corresponding author: Lee, Minjae, Professor, Department of Civil Engineering Chungnam National University, Daejeon, South Korea 305-764

E-mail: lmjcm@cnu.ac.kr

Received July 19, 2019; revised September 16, 2019

accepted September 23, 2019

된 기계학습 라이브러리 개발로 인하여 딥러닝 기법을 활용한 예측 모델 개발이 여러 분야에서 연구가 활발하게 진행되고 있다. 딥러닝은 인공신경망(Artificial Neural Network; ANN)에 기반하여 설계된 개념으로 여러 비선형 변환기법의 조합을 통해 높은 수준의 추상화를 시도하는 기계학습 알고리즘의 집합으로 정의되며, 기존의 통계적인 방법보다 예측모델의 추정력이 크게 개선되어진다는 연구 결과가 있다 (Han et al., 2017a).

따라서 본 연구에서는 딥러닝 기반 도로포장 열화 예측 모델의 개발을 위해 심층신경망(Deep Neural Network; DNN)과 시계열 데이터 분석에 강점을 가진 순환신경망(Recurrent Neural Network; RNN)을 활용하여 고속도로 포장의 시간경과별 열화량을 학습하고, 학습된 모델의 성능을 비교·분석하여 더 우수한 모델을 제안하였다.

1.2 연구의 범위 및 방법

도로포장은 한순간에 파손되는 것이 아니라 여러 변수들에 의한 스트레스 누적으로 인하여 점차 열화가 진행되다가 파손된다. 이에 고속도로 포장의 열화 예측 모델 개발을 위해 도로파손에 영향을 주는 변수들을 기존문헌 고찰을 통해 선정하였다. 딥러닝 분석을 위해서는 데이터 셋을 구축해야 하므로 기존문헌 고찰을 통해 선정된 포장 열화에 영향을 주는 축하중 교통량(Equivalent Single Axle Load; ESAL) 및 환경 변수 총 6개의 데이터와 t년도 고속도로 포장상태지수(Highway Pavement Condition Index; HPCI)를 입력 데이터로 하고 t+n년 HPCI를 출력 데이터로 하는 데이터 셋을 구축하였다. 구축된 데이터 셋을 기반으로 텐서플로우를 활용하여 DNN과 RNN-LSTM (Long Short-Term Memory) 알고리즘을 적용한 딥러닝 기반 열화예측 모델을 개발하였다. 마지막으로 트레이닝 셋과 테스트 셋의 제공된 평균 오차(Root Mean Square Error; RMSE)와 정확도(Accuracy)를 고려하여 개발된 모델의 성능을 비교하고 성능이 우수한 모델을 제안하였다.

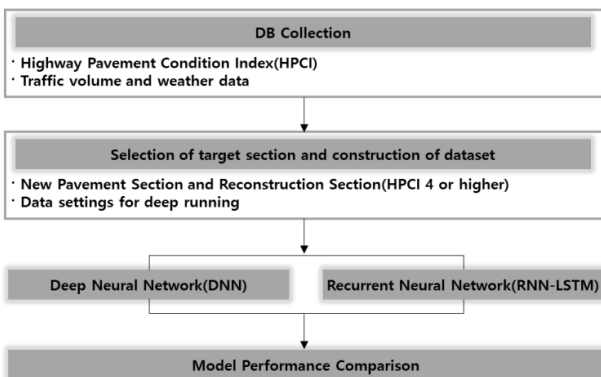


Fig. 1. Research Methodology

2. 기존 연구 고찰

도로포장 파손예측 모델과 관련된 연구는 크게 통계적인 방법론과 마르코프 체인 등을 활용한 확률론적 기법으로 구분되어 왔다.

먼저 통계적인 방법으로는 Lee (2013)는 신뢰성 공학을 활용하여 도로포장의 ESAL을 소, 중, 대로 그룹을 분류하고 모수적 방법으로 그룹별 분포를 추정한 뒤, 평균 수명 및 악화량을 산정하여, 열화 예측 모델을 개발하였다.

마르코프 체인 모델을 활용한 방법으로는 Han et al. (2017b)은 일반국도 포장상태평가지수인 NHPCI (National Highway Pavement Condition Index)를 기반으로 베이지안 마르코프 다단계 하자드 모형을 적용하여 일반국도 포장의 열화과정을 통해 서비스 등급별 기대수명과 분산정보, 그리고 마르코프 전이확률의 갱신과정을 통한 네트워크 서비스 수준 변화과정을 도출하였다.

최근 들어 많은 양의 데이터를 빠르고 다양하게 분석이 가능한 딥러닝 기법을 활용하여 도로포장의 파손을 예측하는 연구가 활발히 이루어지고 있다.

Choi (2018)는 세 개의 머신러닝(Logistic Regression; LR, Decision Tree; DT, Random Forest; RF) 알고리즘과 1개의 DNN 알고리즘을 사용하여 아스팔트 포장의 공용수명 예측모델 및 균열률의 연간 파손량을 예측하였다. 분석 결과를 살펴보면, 공용수명예측 및 균열률 연간 파손량 예측 시 DNN의 모델이 RMSE 측면에서 가장 우수한 성능을 보이는 것으로 나타났다.

Yang et al. (2003)은 전반적인 포장상태는 개별 상태 지수와 상호의존적이라고 하였으며, 이에 세 가지 핵심지표인 균열, 러팅, IRI의 개별적인 열화예측 모델을 ANN을 사용하여 개발하였다. 연구 결과, 각각의 ANN 모델은 과거 데이터베이스에 포함된 기본 정보를 바탕으로 향후 도로포장 열화에 대한 합리적인 예측이 가능하게 되었다.

Suman, S.K. et al. (2012)은 포장 표면 상태(Pavement Condition Index; PCI)에 대한 ANN 접근방식을 제시하며, 삼층 후방 전파 알고리즘을 사용하였다. 제안한 ANN모델은 관측된 PCI와 거의 동일하게 예측하는 것으로 분석되었으며, 이에 향후 15년 이상 PCI를 예측하여 장기적으로 유지보수 및 수리 작업 계획 시 관리자가 의사결정을 할 수 있도록 제안하였다.

DOMITROVIC, J. et al. (2018)은 포장관리시스템의 주요 구성 요소는 ANN과 같은 포장 성능 예측 모델이라 하였으며, 인공 신경망의 기존 분류 평가 가능성 및 국도 유지 전략 수립을 위한 적용 방안을 분석하였다. 또한, 인공 신경망을 사용하여 세계 공용 지수를 결정하고 적절한 포장 유지

관리 계획 시나리오 가능성을 검토하였다. 역전파 신경망을 Osijek-Baranja 주의 국도 481.3km 구간에 적용하고, 그 결과를 토대로 ANN이 프로젝트 및 네트워크 수준에서의 포장상태 평가에 사용될 수 있음을 도출했다.

이와같이, 최근 도로포장 열화예측 모델과 관련된 활용한 국내의 연구의 동향을 살펴보면 기존 간단한 통계분석이나 마르코프 체인과 같은 확률론적인 방법에서 여러 변수들을 고려할 수 있고 데이터가 축적될수록 예측의 정확도가 향상되는 딥러닝을 활용하는 환경으로 변화하고 있다. 그러나 시계열 분석에 강점을 가진 RNN 기법을 활용하여 도로포장의 열화를 예측하는 연구는 국내에서 찾아보기 어려운 것으로 나타났다.

현재 우리나라 고속도로 열화 예측 모델은 <Table 1>과 같이 현재 국내 고속도로 포장관리시스템(Highway Pavement Management System; HPMS)에서 제시하고 있는 포장열화예측 모델은 단순히 공용연수에 따라 HPCI가 감소하는 간단한 1차 선형 회귀 식으로 되어 있어 ESAL 및 환경 변수를 고려하지 못하는 실정이다.

Table 1. Predictability Model by Pavement Type

Type	Predictability Model
Asphalt Pavement	$HPCI_n = HPCI - 0.095 \times n$
Concrete Pavement	$HPCI_n = HPCI - 0.072 \times n$
Composite Pavement	$HPCI_n = HPCI - 0.094 \times n$

※ source: Park (2013)

3. 딥러닝의 방법론

ANN의 종류는 신경망 학습알고리즘과 패턴분류, 음성인식, 문자인식, 영상인식 등과 같은 적용목적에 따라 나뉘질 수 있다. 함수근사 또는 수치연산, 수학적 모델링에 대한 적용을 목적으로 하는 다양한 학습알고리즘 중에서 가장 널리 이용되고 있는 역전파 학습 알고리즘을 사용하는 DNN은 성능의 안정성 및 사용상의 간편성 등으로 인해 널리 이용되고 있다.

하지만 DNN은 시간에 따른 메모리가 존재하지 않기 때문에 시간에 따라 변화하는 연속성을 가진 입력에 대해서는 적합하지 않은 특성이 있다. 이러한 시간의 연속성을 구현하기 위하여 연구된 모델이 RNN이다.

RNN은 시계열 데이터와 같이 시간의 흐름에 따라 변화하는 데이터를 학습하기 위한 인공신경망이다. 그러나 RNN은 기억에 사용되는 내부 상태 값이 시간 step의 이동에 따라 점점 기억하지 못하고 사라지게 만드는 Vanishing Gradient Problem을 가지고 있다.




Fig. 2. Vanishing Gradient Problem

<Fig. 2>는 시간 1에서 입력된 데이터가 얼마만큼 오랫동안 네트워크에 영향을 주는지에 대한 감도를 표현한 것이다. 시간 2~7의 입력은 고려하지 않았으며 오로지 시간 1의 데이터의 영향력을 표현하는 것에 초점을 두었다. 입력된 시간 1과 그 직후 시간에는 네트워크에 강한 영향력을 끼치지만 시간의 흐름에 따라 데이터의 영향력은 점차 감소하다가 사라지는 문제점이 있다. 이러한 네트워크 학습의 경사가 거의 사라지는 현상을 Vanishing Gradient Problem이라 한다.

이러한 문제점을 해결하기 위해 좀 더 복잡한 형태의 RNN 구조인 LSTM 네트워크가 만들어 졌다. 여기서 RNN-LSTM은 RNN이 가지고 있는 Vanishing Gradient Problem을 해결하기 위해 셀스테이트(Cell State)를 가지는 구조이다.




Fig. 3. Structure of RNN and LSTM Cells

LSTM은 <Fig. 3>과 같이 전체 체인을 지나가는 셀 스테이트를 가진 구조를 이용하여 과거의 학습결과를 현재 학습에 그대로 전달하여 RNN의 장기 의존성 문제를 해결하였다.




Fig. 4. How Gradient Information is Stored in RNN-LSTM

<Fig. 4>와 같이 셀 스테이트는 게이트(Gate)라는 요소를 활용해서 정보를 더하거나 제거하는 기능을 수행한다. 0는 게이트가 열려있음을, -는 게이트가 닫혀있음을 뜻한다. 시간 1에서의 데이터를 받은 이후에 Input Gate를 닫아 새로운 정보를 받지 않고, Forget Gate를 열어놔서 시간 1에서

의 입력 데이터를 계속해서 전달받으면, 시간 1에서의 입력 데이터의 영향력을 계속해서 가져갈 수 있다. 마지막으로, Output Gate를 열고 닫으면서, 시간 1에서의 입력 데이터의 영향력을 반영하거나 반영하지 않을 수 있다.

기존 RNN은 Hidden Layer에서 Hidden State (St)를 계산할 때 단순히 $St = \tanh(Uxt + WSt)$ 로 계산하였지만, LSTM에서는 메모리 역할을 수행하는 셀 스테이트와 연결의 강도를 조절하는 3개의 Gate로 구성이 된다.

셀 스테이트는 Forget Gate와 Input Gate를 거친 후 다음 상태로 이동하는데 주로 정보 기억을 담당하고, Forget Gate는 셀상에서 크게 중요하지 않은 정보를 삭제한다. LSTM은 첫째 시그모이드 함수를 사용하여 삭제할 정보를 결정, 둘째 또 다른 시그모이드 함수와 tanh 함수를 사용하여 새로운 정보를 셀 스테이트에 저장할지 결정, 셋째 셀 스테이트를 갱신, 넷째 마지막 시그모이드 함수와 셀 스테이트에서 나오는 출력을 통과한 마지막 tanh 함수로 어떤 값을 출력할지를 결정한다.

Forget Gate Layer는 식 (1)과 같다.

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

Input Gate Layer는 식 (2)와 같이 쓸 수 있고, \tilde{c}_t 는 식 (3)과 같이 쓸 수 있다.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{c}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (3)$$

Update Cell State는 식 (4)와 같이 쓸 수 있다.

$$c_t = f_t * c_{t-1} + i_t * \tilde{c}_t \quad (4)$$

Output Gate Layer는 식 (5), h_t 는 식 (6)과 같이 쓸 수 있다.

$$O_t = \sigma(W_o [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = O_t * \tanh(c_t) \quad (6)$$


4. 딥러닝을 활용한 열화 예측 모델 개발

4.1 대상구간 선정

본 연구에서는 고속도로 포장 열화 예측 모델 개발을 위해 2008년~2016년까지의 HPCI 데이터를 고속도로 포장관리 시스템에서 수집하였다.

고속도로 데이터의 포장형식은 총 6개의 형식으로 AP교면, AP복합단면, AP토공, CP교면, CRCP, JCP로 나뉘어져

있으며 그 중 많은 비중을 차지하고 있는 콘크리트 JCP를 대상으로 분석하였다(Fig. 5).



※ source: Korea Expressway Corporation (2018)

Fig. 5. Ratio by Pavement Type (2017)

콘크리트 JCP포장의 HPCI는 포장상태조사를 통하여 확보된 표면손상 및 평탄성의 정량화된 데이터를 변수로 산출되며, 유지보수 대상구간 선정 및 각종 현황 분석에 활용되며 식 (7)과 같이 산정한다.

$$HPCI_{10m} = 5 - 0.8 \times IRI^{0.7} - 0.85 \times \log(1 + 10 \times 2.5 \times SD) \quad (7)$$

$$\text{여기서, } HPCI_{100m} = \sum_n^{n+10} (HPCI_{10m})$$

평탄성(International Roughness Index) = 평탄성지수(m/km)

표면손상(Surface Distress) = 노면손상 환산면적(m²)

또한 포장 데이터는 일반적으로 별다른 유지보수가 없었던다면 HPCI 값은 낮아지는 것이 일반적이다. 이에 후 년도 자료에서 해당 구간의 HPCI가 높아지는 지점은 잘못된 데이터 또는 유지보수가 된 지점으로 간주하고 제외하였다.

포장은 시간이 경과됨에 따라 여러 파손원인 변수들에 의한 스트레스 누적으로 인하여 점차 열화되다가 파손되는 것이기 때문에 도로포장의 정확한 공용연수를 파악하여, 누적된 하중량을 고려할 수 있어야 한다.

그러나 현재 고속도로 포장관리시스템 데이터는 유지보수 이력데이터가 입력되어 있지 않아 대상구간의 공용연수가 불확실하였다.

따라서 본 연구에서는 2008년을 기준년도로 선정하고 그 해 HPCI가 4이상이며, SD 값 0m², IRI 값 1.18m/km 이하인 포장상태 값이 초기 값인 구간만을 대상으로 수집하였다. IRI의 값의 경우, 도로포장 구조 설계 요령에서 초기 IRI의 값을 1.18m/km~1.41m/km로 제시하고 있어, 본 연구에서는 데이터의 신뢰성 확보를 위하여 1.18m/km 값을 기준으로 하였다.

이러한 데이터 가공 과정을 거쳐 <Table 2>와 같이 약 48,625개 구간에서 총 11,552개 구간을 선정하였다.

Table 2. Data Collection Status

Data Collection Status	
Route	9 Route
Area	Gwangju, Yeonggwang, Sunchang, Changwon, Cheongju, Jeonju, Yangsan, Bukchangwon, Ulsan, Daegu, Gumi, Chunwolryeong, Daejeon, Jinju, Tongyoung, Sancheong, Jangsu, Geumsan, Suwon, Icheon, Cheonan

〈Table 3〉은 우리나라 고속도로 도로포장상태조사 평가 결과에 의한 등급기준이며, HPCI 개량기준(3.0이하)과 미국의 PSI지수, 일본의 MCI 지수에 의한 기준 등을 참고하여 결정되었다(Korea Expressway Corporation, 2018).

Table 3. Grading Standard by Highway Pavement Condition Index

Level	HPCI	Condition	Measure
Level 1	More than 4.00	Very good	Do nothing
Level 2	More than 3.50 and less than 4.00	Good	Preventive repair
Level 3	More than 3.25 and less than 3.50	Somewhat good	Repair and maintenance if necessary
Level 4	More than 3.00 and less than 3.25	Normal	Repair and maintenance
Level 5	More than 2.50 and less than 3.00	Somewhat poor	Improvement if necessary
Level 6	More than 2.00 and less than 2.50	Poor	Improvement
Level 7	Less than 2.00	Very poor	Improvement on a preferential basis

* source: Korea Expressway Corporation (2018)

〈Table 4〉와 같이 선정된 구간의 최초 평균 HPCI는 4.21이며 8년 경과 후 평균 HPCI는 3.5로 다소 우수한 상태를 유지하고 있는 것으로 분석되었다. 이는 교통량이 많고 통행 속도가 빠른 고속도로의 특성상 안전사고 예방을 위한 상시 보수로 인한 것으로 판단된다.

Table 4. Average HPCI of The Target Section

	Initial	After 1 year	After 2 years	After 3 years	After 4 years	After 5 years	After 6 years	After 7 years	After 8 years
HPCI	4.21	4.14	4.07	3.99	3.9	3.82	3.74	3.62	3.5

Table 6. Data Set

		N	Minimum value	Maximum value	Average	Standard deviation
Environment Factors	1. Highway Pavement Condition Index(HPCI)	11,552	1.0	5.0	3.9	0.3
	2. Number of days with intense heat	11,552	0.0	54.0	16.1	12.5
	3. Precipitation	11,552	728.0	2189.5	1198.5	326.7
	4. Number of days with the average temperature of less than 0°C	11,552	4.0	80.0	41.9	18.0
	5. Number of days with the lowest temperature of less than -2°C	11,552	17.0	120.0	74.9	21.8
	6. Number of snow days	11,552	0.0	27.0	5.0	7.0
Transportation Factor	7. ESAL	11,552	0.7	29,319.7	7,509.3	7,332.8

4.2 변수 선정 및 모델링 구조

최근 들어 폭염, 한파, 집중호우 등 국내의 이상기후 현상으로 인해 1950년대 이후 기온 상승률은 20세기 전체 기간에 비하여 약 1.5배 이상 증가하였다. 특히, 최근 100년 동안 국내 평균기온이 약 1.7°C 상승되는 등 급격한 기후변화로 인하여 2000년도 이후 폭설, 집중호우, 한파 등 기상이변이 빈번하게 발생하여 표면손상, 소성변형, 포트홀 등과 같은 조기 파손으로 도로포장의 평균수명이 현격히 감소하고 있다. 이와 같은 도로 포장에 미치는 환경하중의 변화로 도로의 상황은 더욱 열악해지고 있다.

이에 한국도로공사에서는 〈Table 5〉와 같이 “노출환경 등급 지침”을 작성하였으며, 특수환경(다설한랭) 노출 지역은 다음의 ①, ②, ③, ④ 항목 중 3개 항목 이상이 포함되어야 하고, ①은 반드시 해당되어야 한다고 제시하였다.

다음의 ①, ②, ③, ④ 각 항목의 값은 최근 국내 기상의 5개년 평균 값이다(Korea Expressway Corporation, 2010).

Table 5. Guidelines for Grading of Exposure Environments

		Instruction
① Number of freezing and thawing days per year	Daily average temperature (Note 1) less than 0°C	45 days or more
	Lowest daily average temperature (Note 2) less than -2°C	90 days or more
② Annual deicing agent usage		13 tons / two-lane · km or more
③ Annual accumulated amount of snowfall		60cm or more
④ Number of snowing days per year		14 days or more
⑤ Average altitude of the route		450m or more

* source: Korea Expressway Corporation (2010)

또한, 포장의 수명(공용성)은 교통량, 대형차량 비율, 평탄성 등 다양한 인자들의 영향을 받으며, 특히 교통하중 특성과 기초의 두께 등이 포장의 수명에 큰 영향을 미친다(You et al., 2002; Loizos et al., 2005; Yang et al., 2005).

교통하중의 경우 총 교통량(AADT: Annual Average Daily Traffic)과 같은 절대 값 보다는 하중의 강도 예를 들어, ESAL 크기가 포장의 수명에 더 큰 영향을 미친다는 연구결과가 많이 있다(Kwon et al, 2002; Gharaibeh et al., 2003).

따라서 본 연구에서는 ESAL 및 환경변수에 따른 도로포장 열화예측 모델 개발을 위하여 <Table 6>과 같이 포장에 파손을 주는 인자인 폭염일수, 강수량, 평균기온 0도 이하일수, 최저기온 -2도 이하 일수, 적설일수, ESAL과 $HPCI_t$ 를 입력데이터로 하며, 출력은 $HPCI_{t+1}$ 로 하는 DNN과 RNN-LSTM 모델을 구축하였다.

4.3 학습결과

본 논문은 구글에서 제공하는 텐서플로우를 사용하여 모델을 개발하였다. 텐서플로우는 연구자의 입장에서 딥러닝 구동에 필요한 하드웨어적인 요소가 아닌 딥러닝의 구조에 집중할 수 있는 구조로 해당 분야에 최적화된 모델을 구축하는데 있어 생산성 등의 향상을 도모할 수 있는 장점이 있다 (Abadi et al., 2016; Choi, 2018). 본 연구에서 구현한 도로포장 열화 예측 모델의 성능을 평가하기 위하여 HPMS 데이터를 txt 파일로 변환시켜 이 중 80%는 학습 데이터로 사용하고, 20%는 테스트 데이터로 사용하였다.

신경망은 -1~1사이의 값에서 가장 잘 작동하므로 신경망에 입력하기 전에 데이터 값의 범위를 조정해야 한다. 따라서 다음 식을 통하여 정규화 작업을 실시하였다(Park, 2018).

$$\text{정규화} = (\text{요소값} - \text{최소값}) / (\text{최대값} - \text{최소값}) \quad (8)$$

모델 구축과 학습 수행은 학습 시간과 정확도를 고려하여 시행착오를 거쳐 설정하였다.

DNN을 통한 분석 결과는 학습률, 은닉층의 개수, 층별 노드 등과 같은 설정에 크게 영향을 받는다. 본 연구에서 활용한 DNN모델의 노드수는 컴퓨터 사양을 고려하여 20개로 설정하였으며, 은닉층의 개수는 최적의 성능이 나타나는 모델을 구성하기 위해, 1개, 2개, 4개, 8개로 구분하여 학습하였다. <Fig. 6>은 7개의 입력층과 1개의 출력층 사이에 은닉층이 2개인 DNN 모델링 구조 예시이며, <Table 7>은 모델 소스 코드 예시이다.




Fig. 6. Example of DNN Modelling Structure

Table 7. Example of DNN Hidden Layer Creation Source

```

W1 = tf.get_variable("W1", shape=[Num_XData, 20],
                    initializer=tf.contrib.layers.xavier_initializer())
b1 = tf.Variable(tf.random_normal([20]))
L1 = tf.nn.relu(tf.matmul(X, W1) + b1)
W2 = tf.get_variable("W2", shape=[20, Num_YData],
                    initializer = tf.contrib.layers.xavier_initializer())
b2 = tf.Variable(tf.random_normal([Num_YData]))
hypothesis = tf.matmul(L1, W2) + b2
    
```

RNN-LSTM 모델구조에 사용한 파라미터는 시퀀스의 길이(시계열데이터 입력 개수), 입력변수 개수, 출력변수 개수, 은닉층의 출력 크기, 은닉층의 수, epoch 횟수, 학습률 등이다.

시퀀스의 길이는 시계열데이터 입력 개수로 본 연구에서는 2008년~2016년까지의 시계열데이터가 입력되므로 시퀀스의 길이는 8이다. 그리고 입력변수 개수와 출력변수 개수는 4.2절에서 설명한 바와 같이 7개의 입력변수와 1개의 출력 변수로 구성되었다.

텐서플로에서는 <Table 8>과 같이 MultiRNNCell 코드를 이용해 RNN Cell을 여러 층으로 쌓을 수 있다. 먼저 tf.nn.rnn_cell.LSTMCell 코드를 이용해 LSTM Cell의 출력크기(노드수), Forget_bias(망각편향) 등의 파라미터를 입력하여 LSTM 셀을 구현하고, 이것을 MultiRNNCell 코드로 쌓아 은닉층이 여러개인 deep-RNN을 구현할 수 있다.

Table 8. Example of RNN-LSTM Hidden Layer Creation Source

```

def lstm_cell():
    cell = tf.nn.rnn_cell.LSTMCell(num_units=rnn_cell_hidden_dim,
                                  forget_bias=forget_bias, state_is_tuple=True,
                                  activation=tf.nn.tanh)
    if keep_prob < 1.0:
        cell = tf.contrib.rnn.DropoutWrapper(cell,
        output_keep_prob=keep_prob)
    return cell

stackedRNNs = [lstm_cell() for _ in range(num_stacked_layers)]
multi_cells = tf.contrib.rnn.MultiRNNCell(stackedRNNs,
state_is_tuple=True) if num_stacked_layers > 1 else lstm_cell()
    
```

본 연구에서는 LSTM Cell의 출력크기(노드수)는 DNN과 마찬가지로 20개인 LSTM 셀을 구현하였으며, 은닉층의 수는 DNN과 마찬가지로 1, 2, 4, 8개로 구분하여 학습하였다.

<Table 9>는 RNN-LSTM의 파라미터 값을 나타낸 표이며, <Fig. 7>은 본 연구에서 사용한 LSTM의 층이 2개인 모델링 구조 예시이다.

여러 층의 RNN Cell을 쌓게 되면 오버피팅(overfitting)되기 쉽기 때문에 RNN layer의 전과 후에 드롭아웃(dropout) layer를 추가할 수 있다. 또한, RNN layer 사이에도 드롭아웃을 적용할 수 있는데, 텐서플로에서는 tf.nn.rnn_cell.

DropoutWrapper를 이용해 RNN layer 사이에도 드롭아웃을 적용할 수 있다.

Table 9. Set of values for hyperparameters(RNN-LSTM)

Hyper parameters	Value
Sequence length	8
Input dim	7
Hidden dim	20
Output dim	1
Num stacked layer	1, 2, 4, 8

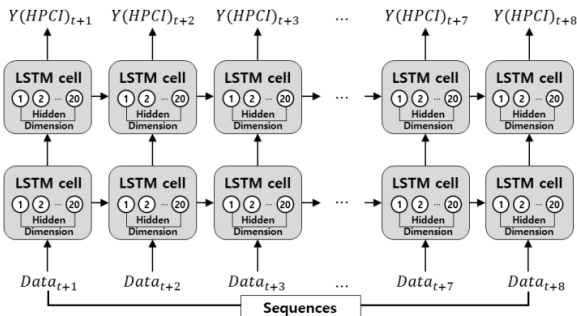


Fig. 7. Example of RNN-LSTM Modelling Structure

또한 DNN과 RNN-LSTM 모델 모두 최적화 함수로는 최적화 수렴속도가 빠르며 안정적인 Adam Optimizer를 사용하였으며, 0.001의 학습률로 10,000번의 반복 학습을 하였다.

모델의 성능(오차)을 측정하는 척도로 비용함수(Cost Function)를 많이 사용한다. 모델의 비용함수는 일반적으로 많이 적용되는 RMSE를 통해 확인하였다. RMSE는 실제 값(p_i)과 추정값(y_i)의 차이가 클수록 더 큰 오차를 나타내는 값으로 작을수록 정밀도가 높은 모델이다.

$$\text{제곱근 평균오차} = \sqrt{\frac{1}{n} \sum_{i=1}^n (p_i - y_i)^2} \quad (9)$$

<Table 10>과 <Fig. 8~9>는 딥러닝 모델별 은닉층 개수에 따른 RMSE 결과이다. 두 모델 모두 학습 RMSE와 테스트 RMSE 값의 차이가 크지 않아 과적합은 발생하지 않은 것으로 분석되었다.

RNN-LSTM 모델의 경우, 은닉층의 개수가 많아질수록 RMSE 값이 커지는 것을 알 수 있었으며, 은닉층의 개수가 1개일 때 테스트 RMSE 값이 0.102로 가장 낮은 것으로 분석되었다. DNN 모델의 경우, 은닉층의 개수가 많아질수록 RMSE 값은 감소하다가 다시 증가하였으며, 은닉층이 2개일 때 RMSE 값이 0.130로 가장 낮은 것으로 분석되었다.

이에 최적 RNN-LSTM 모델(은닉층 1개)과 최적 DNN 모

델(은닉층 2개)을 비교해보면, 모델의 성능은 RNN-LSTM이 DNN 모델보다 RMSE 값이 작아 더 우수한 것으로 분석되었다.

Table 10. RMSE Result

		Train error	Test error
RNN-LSTM	1-Hidden Layer	0.085	0.102
	2-Hidden Layer	0.079	0.115
	4-Hidden Layer	0.134	0.163
	8-Hidden Layer	0.158	0.167
DNN	1-Hidden Layer	0.149	0.147
	2-Hidden Layer	0.134	0.130
	4-Hidden Layer	0.134	0.132
	8-Hidden Layer	0.136	0.133




Fig. 8. Comparison by RNN-LSTM Hidden Layer

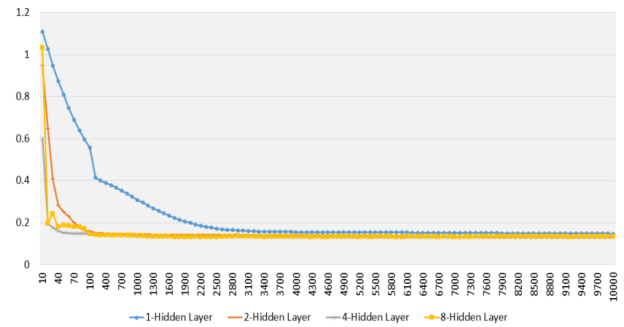


Fig. 9. RMSE Comparison by DNN Hidden Layer

딥러닝별 최적 모델의 분석결과에 해당하는 정확도(Accuracy)는 결정계수를 통해 나타낼 수 있도록 모델을 구성하였으며, 산정식은 Eq (10)과 같다.

$$R\text{-squared} = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \mu)^2} \quad (10)$$

여기서, y_i 는 실측 HPCI 값, \hat{y}_i 는 딥러닝에 의해 예측된 HPCI 값, μ 는 실측 HPCI의 평균 값, n 은 샘플 수를 의미한다. 텐서플로우에서는 `r2_score($y_i, \hat{y}_i, \text{multioutput}$)` 코드를 활용하여 결정계수를 산정할 수 있다.

분석결과, 최적 RNN-LSTM 모델의 경우 결정계수가 0.915로 매우 높은 예측력을 보였으나, DNN 모델의 경우 0.365로 해당 모델의 예측력은 매우 낮았다.

Table 11. R-squared Result

	RNN-LSTM (1-Hidden Layer)	DNN (2-Hidden Layer)
R-squared	0.915	0.365

〈Table 12〉와 〈Fig. 10〉은 두 모델의 대상구간 시간경과별 평균 HPCI 예측치와 실제 평균 HPCI 실측치의 비교결과이다. RNN-LSTM 모델은 실제 HPCI 실측치와 매우 유사하였으나, DNN 모델의 경우 시간이 경과될수록 실측치와 예측치의 오차범위가 점점 커지는 것으로 분석되었다.

따라서, 향후 고속도로 콘크리트 포장의 유지관리 계획 수립시 유지보수 수요 추정을 위한 열화 예측 모델로는 DNN 모델보다 시계열 분석에 강한 RNN-LSTM의 모델을 제안한다.

Table 12. Comparison of Prediction Results of Pavement Deterioration by Deep Learning Model

	Actual Value	Predicted Value	
		RNN-LSTM (1-Hidden Layer)	DNN (2-Hidden Layer)
Initial	4.21	4.21	4.21
After 1 Year	4.14	4.14	4.05
After 2 Year	4.07	4.08	3.81
After 3 Year	3.99	3.98	3.45
After 4 Year	3.90	3.88	3.20
After 5 Year	3.82	3.84	3.02
After 6 Year	3.74	3.72	2.86
After 7 Year	3.62	3.66	2.72
After 8 Year	3.50	3.49	2.60

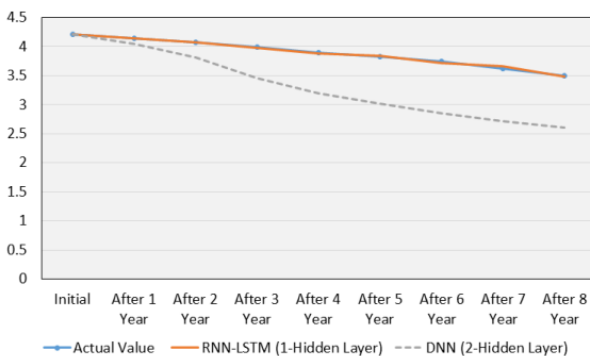


Fig. 10. Comparison between Actual and Predicted Values

5. 결론

도로포장의 전략적 유지보수 계획 수립을 위해서는 포장의 유지보수 시기 및 공법 결정을 위한 의사결정체계가 필요하며, 이 과정에서 해당 도로구간의 열화 예측이 매우 중요하다. 따라서 본 연구에서는 고속도로 포장 열화예측 모델 개발을 위해 2008년~2016년까지의 HPCI 데이터와 도로포장 열화에 영향을 주는 ESAL 및 환경변수 총 6개의 데이터를 활용하여 딥러닝 방법론을 통해 고속도로 콘크리트 포장의 시간경과별 열화량을 예측하고 모델의 성능을 비교하였다.

먼저, ESAL 및 환경 변수 총 6개의 데이터와 t년도 HPCI를 입력변수로 하며, 입력변수를 통해 t+n년 HPCI를 출력하는 데이터 셋을 구축하고 텐서플로우를 활용하여 딥러닝 기반 열화예측 모델을 개발하였다. 모델의 검증으로는 실제 값과 추정 값의 차이가 클수록 더 큰 오차를 나타내는 RMSE 값을 통해 확인하였다.

RNN-LSTM 모델의 경우, 은닉층의 개수가 많아질수록 RMSE 값이 커지는 것을 알 수 있었으며, DNN 모델의 경우, 은닉층의 개수가 많아질수록 RMSE 값은 감소하다가 다시 증가하였다.

이에 최적 RNN-LSTM 모델(은닉층 1개)과 최적 DNN 모델(은닉층 2개)의 성능을 비교해보면, RNN-LSTM 모델의 RMSE 값이 0.102로 DNN모델 RMSE 값 0.130보다 낮아 모델의 성능이 더 우수하였다. 또한, 두 모델의 대상구간 시간경과별 평균 HPCI 예측치와 실제 HPCI 실측치의 비교를 통해 RNN-LSTM 모델의 높은 정확도를 검증하였다. 이는 고속도로 포장은 시간이 경과됨에 따라 파손이 되는 시계열 데이터의 특성을 가지고 있어 RNN-LSTM이 보다 좋은 결과를 도출한 것으로 판단된다.

이에 본 연구의 결과를 바탕으로 보다 정확한 유지보수 필요 구간의 예측이 가능함에 따라 향후 고속도로 포장 유지보수 계획 수립시 유지보수 예산 추정에 중요한 기초정보로 활용될 수 있을 것이라 기대된다.

감사의 글

본 연구는 한국연구재단 이공분야기초연구사업(NRF-2017R1D1A1A09000687)의 연구비 지원에 의해 수행되었으며, 이용준(2019) 박사학위 논문 일부를 인용하였습니다.

Reference

- Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., and Ghemawat, S. (2016). "Tensorflow: Large-scale machine learning on heterogeneous distributed systems." arXiv preprint arXiv:1603.04467.
- Choi, S. (2018). "Development of Road Asset Management System based on Artificial Intelligence using Visual Information." Doctoral Thesis.
- Do, M. (2011). "Comparative analysis on mean life reliability with functionally classified pavement sections." *International Journal of Highway Engineering*, 14(5), pp. 11–19.
- Do, M., Lee, Y., Lim, K., and Kwon, S. (2011). "Estimation of Performance and Pavement Life using National Highway Pavement Condition Index." *KSCE Journal of Civil Engineering*, 15(2), pp. 261–270.
- DOMITROVIĆ, J., DRAGOVAN, H., RUKAVINA, T., and DIMTER, S. (2018). "Application of an Artificial Neural Network in Pavement Management System." *Tehnički vjesnik*, 25(2), pp. 466–473.
- Gharaibeh, N., and Darter, M. (2003). "Probabilistic analysis of highway pavement life for Illinois." *Transportation Research Record 1823*, No.03–4294, pp. 111–120.
- Kobayashi, K., and Do, M. (2010). "Estimation of Markovian transition probabilities for pavement deterioration forecasting." *KSCE Journal of Civil Engineering*, 14(3), pp. 343–351.
- Korea Expressway Corporation (2010). "Guideline for Exposure to Environment."
- Korea Expressway Corporation (2018). "2017 Investigation and analysis of highway pavement condition."
- Kwon, S., Jeong, K., and Sun, Y. (2012). "A Study on Decision Criteria of traffic volumes for Choosing of Modified Asphalt Pavement in Korea National Highway." *International journal of highway engineering*, 4(3), pp. 25–33.
- Han, D., Yoo, I., and Lee, S. (2017a). "Improvement of Multivariable, Nonlinear, and Overdispersion Modeling with Deep Learning: A Case Study on Prediction of Vehicle Fuel Consumption Rate." *Intl. Journal of the Highway Engineers*, 19(4), pp. 1–7.
- Han, D., Do, M., and Kim, B. (2017b). "Internal Property and Stochastic Deterioration Modeling of Total Pavement Condition Index for Transportation Asset Management." *International journal of highway engineering*, 19(5), pp. 1–11.
- Hochreiter, S., and Schmidhuber, J. (1997). "Long Short-Term Memory." *Neural Computation archive*, 9(8), pp. 1735–1780.
- Lee, I., Lee, Y., Park, S., Cho, H., and Lee, M. (2018). "A Study on Utilization of Private Capital for Efficient Highway Pavement Management." *Korean Journal of Construction Engineering and Management*, KICEM 19(1), pp. 3–11.
- Lee, Y. (2013). "A Study on the Method of Establishing Road Maintenance Strategy Considering the Forecasting Traffic Demand." Master Thesis.
- Lee, Y., and Lee, M. (2016). "A Study on Estimating of Probability Distribution and Mean Life of Bridge Member for Effective Maintenance of the Bridge." *Korean Journal of Construction Engineering and Management*, 17(4), pp. 57–65.
- Lee, Y. (2019). "A Study on Construction of Highway Pavement Asset Management System based on Big Data." Doctoral Thesis.
- Loizos, A., and Karlaftis, M.G. (2005). "Prediction of pavement crack initiation from in-service pavements: A duration model approach." *Journal of the Transportation Research Board*, 1940, TRB, pp. 38–42.
- MOLIT (2011). "Road Pavement Structure Design Manual."
- Park, J. (2013). "A Study on the Improvement of Business Process Efficient for Expressway Pavement Management." Master Thesis.
- Park, J. (2018). "Estimation of Electrical Loads Patterns by Usage in the Urban Railway Station by RNN." *The Transactions of the Korean Institute of Electrical Engineers*, 67(11), pp. 1536–1541.
- Suman, S., and Sinha, S. (2012). "Pavement Condition Forecasting Through Artificial Neural Network Modelling." *International Journal of Emerging Technology and Advanced Engineering*, 2(11), pp. 474–478.

- Yang, J., Gunaratne, M., Lu, J.J., and Dietrich, B. (2003). "Application of Neural Network Models For Forecasting of Pavement Crack Index and Pavement Condition Rating." Florida Department of Transportation.
- Yang, J., Gunaratne, M., Lu, J.J., and Dietrich, B. (2005). "Use of recurrent Markov chains for modeling the crack performance of flexible pavements." *Journal of Transportation Engineering*, 131(11), pp. 861–872.
- You, P., and Lee, D. (2002). "Methodology of a Probabilistic Pavement Performance Prediction Model Based on the Markov Process." *International Journal of Highway Engineering*, 4(4), pp. 1–12.

요약 : 도로연장의 지속적인 증가와 공용기간이 상당히 경과한 노후 노선이 늘어남에 따라 도로포장에 대한 유지관리비용은 점차 증가하고 있어, 예방적 유지관리를 통해 비용을 최소화 하는 방안에 대한 필요성이 제기되고 있다. 예방적 유지관리를 위해서는 도로포장의 정확한 열화 예측을 통한 전략적 유지관리 계획 수립이 필요하다. 이에 본 연구에서는 고속도로포장 열화예측 모델 개발을 위해 딥러닝 모델 중 가장 보편적으로 많이 사용하는 심층신경망(DNN)과 시계열 데이터 분석에 강점을 가진 순환신경망(RNN)을 사용하였으며, 두 개의 모델의 성능을 비교·분석하여 우수한 모델을 제안하였다. RNN의 Vanishing Gradient Problem을 해결하기 위해 좀 더 복잡한 형태의 RNN구조인 LSTM(Long short-term memory circuits)을 사용하였다. 학습 결과, RNN-LSTM 모델의 RMSE 값이 0.102로 DNN모델보다 낮아 성능이 더 우수하였다. 또한, 대상구간의 시간경과별 평균 도로포장 상태 예측치와 실제 도로포장 상태 실측치의 비교를 통해 RNN-LSTM 모델의 높은 정확도를 검증하였다. 따라서 향후 고속도로 콘크리트 포장의 유지관리 계획 수립시 유지보수 수요 추정을 위한 열화 예측 모델로는 DNN 모델보다 시계열 분석에 강한 RNN-LSTM의 모델을 제안한다.

키워드 : Pavement Deterioration Prediction, Deep Learning, Recurrent Neural Network, Long Short-Term Memory, Deep Neural Network
