

딥러닝을 활용한 일반국도 아스팔트포장의 공용수명 예측

Prediction of Asphalt Pavement Service Life using Deep Learning

최승현 Choi, Seunghyun | 정회원 · 한밭대학교 도시공학과 박사수료 (E-mail : elflie@naver.com)
도명식 Do, Myungsik | 정회원 · 한밭대학교 도시공학과 교수 · 교신저자 (E-mail : msdo@hanbat.ac.kr)

ABSTRACT

PURPOSES : The study aims to predict the service life of national highway asphalt pavements through deep learning methods by using maintenance history data of the National Highway Pavement Management System.

METHODS : For the configuration of a deep learning network, this study used Tensorflow 1.5, an open source program which has excellent usability among deep learning frameworks. For the analysis, nine variables of cumulative annual average daily traffic, cumulative equivalent single axle loads, maintenance layer, surface, base, subbase, anti-frost layer, structural number of pavement, and region were selected as input data, while service life was chosen to construct the input layer and output layers as output data. Additionally, for scenario analysis, in this study, a model was formed with four different numbers of 1, 2, 4, and 8 hidden layers and a simulation analysis was performed according to the applicability of the over fitting resolution algorithm.

RESULTS : The results of the analysis have shown that regardless of the number of hidden layers, when an over fitting resolution algorithm, such as dropout, is applied, the prediction capability is improved as the coefficient of determination (R^2) of the test data increases. Furthermore, the result of the sensitivity analysis of the applicability of region variables demonstrates that estimating service life requires sufficient consideration of regional characteristics as R^2 had a maximum of between 0.73 and 0.84, when regional variables were taken into consideration.

CONCLUSIONS : As a result, this study proposes that it is possible to precisely predict the service life of national highway pavement sections with the consideration of traffic, pavement thickness, and regional factors and concludes that the use of the prediction of service life is fundamental data in decision making within pavement management systems.

Keywords

deep learning, pavement service life, asphalt pavement, over fitting, deep neural network

Corresponding Author : Do, Myungsik, Professor
Dept. of Urban Engineering, Hanbat National University,
125, Dongseodae-ro, Yuseong-gu, Daejeon, 34158, Korea
Tel : +82.42.821.1192 Fax : +82.42.821.1185
E-mail : msdo@hanbat.ac.kr

International Journal of Highway Engineering
<http://www.ksre.or.kr/>
ISSN 1738-7159 (Print)
ISSN 2287-3678 (Online)

Received Feb. 19, 2018 Revised Feb. 20, 2018 Accepted Apr. 01, 2018

1. 서론

우리나라는 1970~1980년대의 고도 성장기에 집중 건설된 사회기반시설물의 노후화가 이루어지고 있어 도로 포장의 경우 향후 10년 후에는 전체도로의 85%가 재령

20년을 초과할 것으로 예상되고 있다(MOLIT, 2016). 이러한 도로포장의 고령화를 예방하기 위해 국내에서는 포장관리시스템(PMS; Pavement Management System)을 통해 도로포장의 체계적인 유지보수 및 관리

를 위해 노력하고 있다.

포장관리시스템은 도로포장에 관련되는 기본계획, 설계, 시공, 유지보수 및 평가에 이르기까지 도로포장과 연관된 전 단계를 체계적으로 관리하는 시스템으로 최소한의 비용을 투입하여 최상의 포장상태를 유지하는 것을 목적으로 하고 있다.

현재 해외 선진국은 물론 국내에서도 도로포장의 공용성을 포함한 생애주기비용분석, 포장설계 등의 다양한 관점에서 연구가 진행 중이며, 포장관리시스템에서의 최적유지보수 기준은 생애주기비용분석을 기반으로 하고 있기 때문에 초기건설단계에서 발생하는 비용부터 폐기시에 발생하는 비용 전반에 대한 신뢰성 있는 분석이 필요하다. 이러한 도로포장구간의 효율적인 유지관리를 위한 의사결정 로직의 구성 및 생애주기비용분석을 위해서는 신뢰성 높은 포장공용수명(pavement service life)의 예측이 필수적이다.

국내외에서는 포장공용수명의 예측을 위해 다양한 연구가 수행되어 왔으며 크게 회귀식을 기반으로 하는 결정론적 방법론과 마르코프체인(Markov chain)을 필두로 하는 확률론적 방법론으로 구분되어 진다(Do and Kwon., 2010; Mishalani and Madnat, 2002; Kobayashi et al., 2012; Han and Do., 2012). 하지만 결정론적 방법론의 경우 다양하고 복합적인 요인들의 고려가 어려운 점이 있으며 확률론적 방법론의 경우 포장파손의 인과관계와 특성의 변화과정에 대한 정보제공이 어렵다는 측면에서 한계가 있다(Han, 2013).

이러한 불확실하며 복합적인 요소들에 의해 결정되어지는 결과의 경우 기존의 통계적인 방법이 아닌 딥러닝(deep learning) 또는 인공신경망을 기반으로 하는 방법론을 적용할 경우 모델의 추정력이 크게 개선되어진다는 연구도 있다(Han et al., 2017a).

따라서 본 연구에서는 딥러닝(deep Learning)기법을 이용하여 포장 공용수명 예측을 위한 기법을 제시하고자 한다. 이를 위해 3년간의 일반국도 유지보수구간의 공용수명 자료를 이용하였다.

2. 선행연구 고찰

먼저 통계적인 기법을 통해 도로포장의 공용수명을 추정한 연구를 살펴본 결과, Han and Do(2012)는 전국 일반국도포장 모니터링 자료(2007~2010년)를 기준으로 관측치의 확률분포 기댓값을 분석하여 평균 9.7년의 공용수명이 기대됨을 밝혔으며, Han et al(2017b)

은 2007년~2014년의 일반국도 포장 종합평가지수(NHPCI; National Highway Pavement Condition Index)를 베이지안 마르코프 다단계 해저드 모형을 활용하여 공용수명을 예측한 결과 평균 12.9년의 공용수명이 기대됨을 밝혔다.

한편, 국내에서 딥러닝(또는 인공신경망)기법의 적용을 통해 도로포장의 공용수명(공용성)을 예측한 연구는 찾아보기 어려운 것으로 나타났으며 도로포장 이외의 분야에서 Kim and Lim(2016)은 도로의 터널붕괴예측에 관한 기초 연구를 수행함에 있어 오차역전파(EBP; Error Back Propagation)와 쌍곡탄젠트(tanh)를 기반으로 하는 인공신경망 기법을 적용한 바 있으며, Kobayashi et al(2010)은 기존의 통계적인 기법을 활용하여 일반국도 포장 데이터(2003~2006년)를 마르코프 위험률 모델을 활용해 약 9.2년의 공용수명을 제시한 바 있다.

한편, 딥러닝(또는 인공신경망)기법이 도입된 연구로는, Terzi(2007)은 고속도로 포장의 서비스상태지수 모델링을 위해 인공신경망 기법을 적용하였는데 입력변수로는 경사도, 소성변형, 패칭, 균열율을 출력변수로는 PSR (Pavement Surface Rating)을 활용하여 인공신경망 기법의 적용 가능성을 제시한 바 있다. 또한 Attoh-Okine(1999)는 인공신경망의 백프로파게이션(back propagation) 알고리즘을 기반으로 종단평탄성(IRI; International Roughness Index)을 예측한 연구에서 입력변수로 소성변형, 균열률, 축하중 등 총 10가지의 변수를 적용하여 높은 결정계수를 얻는 성과를 얻은 바 있다. 이외에도 Gopalakrishnan et al(2017)은 포장의 파손상태 인식을 위한 연구를 위해 딥러닝 기법을 활용한 바 있다.

위에서 살펴본 바와 같이 딥러닝 기법을 활용한 포장상태지수, 포장상태값의 예측에 관한 연구 사례는 있지만 포장의 공용수명 예측에 관한 연구는 찾아보기 어려운 것으로 나타났다.

3. 방법론

3.1. 딥러닝 기법의 활용

딥러닝(deep learning)은 기존의 인공신경망 구조에서 은닉층(hidden layer)이 증가하게 될 경우 사용되어지는 알고리즘을 말한다. 딥러닝의 알고리즘은 크게 심층신경망(DNN; Deep Neural Network), 합성곱신경망(CNN; Convolutional Neural Network), 순환신

경망(RNN; Recurrent Neural Network), 심층신경망(DBN; Deep Belief Network), 심층 Q-네트워크(Deep Q-Networks) 등으로 구분된다.

이러한 딥러닝 알고리즘을 통한 분석, 개발을 손쉽게 도와주는 역할을 수행하는 것이 딥러닝 프레임워크(deep learning framework) 소프트웨어이며, 딥러닝 모형의 개발을 도와주는 소프트웨어로 대부분 오픈소스의 형태로 공개되어 있다. 대표적인 프레임워크로 Theano, TensorFlow, Torch, Caffe, MXnet, CNTK, Keras 등이 있으며 분석목적 및 데이터유형 등에 따라 적합한 프레임워크를 선택하는 것이 매우 중요하다.

Fig. 1은 각 프레임워크들의 대표적인 특징들을 정리한 것이다. 그 중에서도 TensorFlow는 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). 따라서 본 연구에서는 딥러닝 오픈소스 프레임워크 중 Google Brain사에서 개발한 TensorFlow 1.5를 활용하여 모델을 개발하였다.

	Languages	Tutorials and training materials	CNN modeling capability	RNN modeling capability	Architecture: easy-to-use and modular front end	Speed	Multiple GPU support	Keras compatible
Theano	Python, C++	++	++	++	+	++	+	+
TensorFlow	Python	+++	+++	++	+++	++	++	+
Torch	Lua, Python (new)	+	+++	++	++	+++	++	
Caffe	C++	+	++		+	+	+	
MXNet	R, Python, Julia, Scala	++	++	+	++	++	+++	
Neon	Python	+	++	+	+	++	+	
CNTK	C++	+	+	+++	+	++	+	

(source: <https://svds.com/getting-started-deep-learning/>)

Fig. 1 Comparison of Deep Learning Framework

본 연구에서는 정량화된 입력데이터와 출력데이터를 활용하기 위해 지도학습기법(supervised learning)중 기본이 되는 심층신경망(DNN) 알고리즘을 활용하여 분석을 수행하였다. 여기서 심층신경망 알고리즘은 입력층과 출력층 사이에 여러 개의 은닉층들로 이루어진 인공신경망으로 보통 1개의 은닉층을 얇은신경망(shallow network), 2개 이상의 은닉층을 갖는 인공신경망을 심층신경망이라 한다.

3.2. 과적합과 Dropout 정규화

본 절에서는 여러 은닉층으로 구성된 심층신경망을

통한 예측력 향상에 장애가 되는 과적합(overfitting) 문제의 해결방안에 대해 살펴보기로 한다.

먼저 인공신경망에서 가장 간단한 구조로 구성된 인공신경망을 통해 인공신경망의 개략적인 구조를 살펴보고자 한다. Fig. 2의 인공신경망은 입력층과 출력층으로 구성되어 있다.




Fig. 2 Concept of Neural Networks

입력층에서는 데이터를 벡터 형식으로 입력뉴런(input node)에 입력한다. 가중치 \$w_i\$는 입력된 데이터 \$x_i\$와 출력층의 출력값 \$\hat{y}\$을 최적으로 일치하게 만들어 주는 링크로서, 훈련데이터를 이용해 모형을 학습시킨다(Tan et al., 2006). Eq. (1)은 Fig. 2를 수학적 식으로 표현한 것이다.

$$\hat{y} = f\left(\sum_i^n w_i x_i + w_0 x_0\right) \quad (1)$$

여기서 \$f\$는 활성화 함수(activation function), \$n\$은 입력벡터의 수, \$w_0\$는 바이어스(bias) 기울기, \$x_0\$는 바이어스 입력 값이다. 하지만 Minsky and Papert(1969)는 선형 분리만 가능한 단층 퍼셉트론 개념으로는 비선형 문제에 대한 해결이 어렵다는 것을 지적했으며, 이러한 문제를 해결하기 위해 Werbos(1974)는 역전파(Back Propagation)알고리즘과 입력층과 출력층 사이에 은닉층을 추가하는 방법을 제안하였다.

인공신경망의 학습을 위해 사용되는 대표적인 알고리즘이 바로 역전파 알고리즘이며 크게 전파(propagation) 단계와 가중치 수정단계로 나누어 구성되어진다. 먼저, 전파 단계에서는 초기 설정된 가중치를 통해 훈련 데이터(training data)로부터 출력된 출력(예측)값과 목적(실제)값과의 차이인 오차를 산정하여 각 층에 전달하게 되며 가중치 수정단계에서는 전달이 이루어진 오차를 이용하여 가중치에 대한 수정이 이루어지게 된다. 즉,

$$\delta = \frac{1}{2}(\hat{y} - y)^2 \quad (2)$$


$$w(t+1) = w(t) - \alpha \frac{\partial \delta}{\partial w(t)}$$

Eq. (2)에서 y 는 실제 값, \hat{y} 는 예측 값, δ 는 오차 값을 의미한다. 그 후 오차(δ)가 최소가 되도록 출력층에서 입력층 방향으로 역전파를 반복하여 가중치에 대한 수정이 이루어지게 된다. 여기서 $w(t)$ 는 t 단계에서의 신경망 가중치 값, $w(t+1)$ 은 갱신(update) 후의 가중치 값을 의미한다. 이와 같이 가중치를 계속적으로 갱신해 나가면서 가중치와 설정된 오차함수가 특정 값에 수렴 또는 최소화가 이루어지는 경우 학습을 중단하게 된다.

그러나 심층신경망과 같이 층이 깊어질 경우 다양한 문제가 발생할 수 있으며 이는 크게 네 가지로 구분되어진다. 먼저, 학습 시간이 길어지는 경우로 이는 오차가 지역 최소값(local minima)에 도달해 전역 최소값(global minima)을 찾지 못하여 발생하게 되는 문제이다. 다음으로는 과적합(overfitting) 문제이다. 과적합 문제는 모형이 훈련데이터에만 집중된 학습이 이루어져 훈련데이터 이외의 데이터 셋에 대한 정확도가 낮아지는 문제를 말하며 반대의 경우로 과소추정(underfitting)의 문제가 있다. 셋째는, 학습률(learning rate)과 같은 초기 변수 값의 설정에 따라 비용함수의 수렴에 어려움이 발생할 수 있는 문제, 마지막은 기울기(Gradient) 값이 사라지는 문제(Vanishing Gradient Problem)로 이는 반복적인 학습으로 인해 기울기의 변화량이 작아짐에 따라 비용함수 값이 최소화되지 못한 채 수렴해 가중치에 대한 갱신이 이루어지지 않는 경우를 의미한다.

이러한 심층신경망의 문제점을 해결하기 위해 다양한 방법들이 제안된 바 있다. Hinton et al(2006)은 제한된 볼츠만 머신을 이용한 데이터의 사전학습(pre-training) 후에 심층신경망(DBN)를 학습시키는 방법을 제시한 바 있지만 최근에는 기존의 심층신경망에 학습과정에서 일부 뉴런 사이의 연결을 무작위로 단절시킴으로써 과적합 문제를 해결할 수 있는 Dropout 정규화 기법이 활용되고 있다(Dahl et al., 2013; Srivastava et al., 2014).

Dropout 기법은 Fig. 3의 (b)와 같이 무작위로 일부 뉴런의 출력을 강제적으로 0이 되게 하는 것, 즉 그 뉴런을 사라지게(drop) 하여 대형 신경망을 다수의 소규모 신경망으로 대체해 그 출력의 평균을 구하는 방법으로 이때 데이터 잡음이 효과적으로 감소될 수 있음을 이용하는 기법이다. 일반적으로 은닉층의 뉴런수에 따라 상이하지만 50~80% 정도의 뉴런을 사용하게 된다(Srivastava et al., 2014).



(a) Standard Neural Net (b) After Applying Dropout
(source: Srivastava et al., 2014)

Fig. 3 Dropout Neural Net Model

Dropout기법은 신경망의 뉴런에 베르누이분포를 따르는 변수를 무작위로 곱해주는 것으로 간략히 설명할 수 있으며 여기서 베르누이 랜덤변수는 뉴런이 존재할 확률 p , 평균 p , 분산이 $p(1-p)$ 인 변수이다. 입력뉴런에 이 랜덤변수를 곱해주면 결과적으로 랜덤변수의 값에 따라 뉴런이 줄어들게 된다. Dropout 정규화를 수식화 하면 Eq. (3)과 같이 표현할 수 있다(Srivastava et al., 2014).

$$\begin{aligned} d_i &\sim \text{Bernoulli}(p) \\ \tilde{x}_i &= d_i \times x_i \\ \tilde{y} &= f(w_i \tilde{x}_i + w_0 x_0) \end{aligned} \quad (3)$$

$$\text{s.t. } \sum_k f_k^{rs} = q_{rs}, \quad f_k^{rs} \geq 0 \quad \forall k, r, s$$

$$x_a = \sum_r \sum_s \sum_k f_k^{rs} \delta_{ak}^{rs} \quad \forall a$$

여기서 d_i 는 베르누이분포를 따르는 변수, x_i 는 입력 값, \tilde{x}_i 는 Dropout 적용 후 뉴런, w_i 는 가중치, f 는 활성화함수, \tilde{y} 는 출력 값을 의미한다.

3.3. 활성화 함수

기존에 자주 사용되는 활성화 함수에는 Sigmoid와 tanh함수 등이 있다. 하지만 Sigmoid함수는 앞서 설명한 네 가지 문제점 중의 하나인 기울기(Gradient) 값이 사라지는 문제(Vanishing Gradient Problem)가 발생하게 된다.

즉, 기울기 하강(Gradient decent)이 반복되어짐에 따라 오차가 사라져 버리는 것이다. 이러한 문제점을 해결하기 위해 다양한 활성화 함수들이 제안되었으며 그 중 대표적인 것이 Rectified Linear Unit(ReLU) 활성화 함수이다. 이는 기존의 Sigmoid함수에 비해 더 간단하면서 비대칭적인 ReLU 함수를 통해 신경망을 더

빠르고 효과적으로 학습시킬 수 있음을 증명하였다 (Nair et al., 2010).

또한 Clevert et al(2015)은 ReLU 함수를 개선한 Exponential Linear Unit(ELU)를 제안하였으며 기존의 활성화 함수에 비해 매우 뛰어난 성능을 보여주고 있다.

$$ELU(x) = \begin{cases} x & x \geq 0 \\ \alpha(\exp(x) - 1) & x < 0 \end{cases} \quad (4)$$

여기서, α 값은 주로 1이 적용되며 ReLU 함수와 다른 점은 함수 값이 음수로 나타나게 되는 점이며 특징으로는 지수함수의 특성에 따라 기울기의 감소속도가 빠르다는 점이다.

4. 딥러닝을 활용한 공용수명예측

4.1. 데이터 개요

본 연구에서는 도로포장의 공용수명예측을 위해 일반 국도 유지보수 내시구간(2012~2014년)의 유지보수이력 데이터를 활용하였다. 유지보수 내시구간 이력 데이터는 다음 연도에 유지보수가 예정된 구간의 이력 데이터로 해당 구간의 연장, 유지보수 공법, 교통량, 축하중, 공용수명, 유지보수시의 노면상태(균열률, 소성변형, 종단평탄성) 등의 정보를 포함하고 있어 해당 포장구간의 공용수명 및 변수에 관한 정확한 데이터를 취득할 수 있는 이점이 있다.

해당기간의 유지보수 구간 중 아스팔트포장 구간의 유지보수 구간은 총 759개 구간으로 해당 자료의 평균 공용수명은 10.0년, 표준편차는 3.4년인 것으로 나타났다.

도로포장의 공용수명은 교통, 환경, 포장구조, 지역특

성 등 다양한 요인의 영향을 받으며(Han and Do., 2012; Baek et al., 2015), 본 연구에서도 유지보수 내시구간 이력 데이터를 통해 취득 가능한 교통요인, 포장구조요인, 지역특성의 요인을 고려하여 포장의 공용수명을 산출하는 방법을 제시하고자 한다.

먼저 교통요인에서는 해당 분석 구간을 통과하는 누적 교통량(CAADT; Cumulative Annual Average Daily Traffic)과 누적 축하중(CESAL; Cumulative Equivalent Single Axle Loads) 데이터가 있으며, 국토교통부의 교통량 정보제공 시스템(TMS; Traffic Monitoring System)에서 제공하는 데이터를 활용하였다.

포장의 구조 요인으로는 해당포장구간의 보수층, 표층, 기층, 보조기층, 동상방지층, 포장강도(SNP; Structural Number of Pavement)를 고려하였으며 포장구간의 지역변수로는 각 포장구간의 국토관리청인 서울, 대전, 익산, 원주, 부산의 5개 지역으로 구분하였다.

지역별 공용수명의 차이를 살펴본 결과는 Fig. 4와 같다.

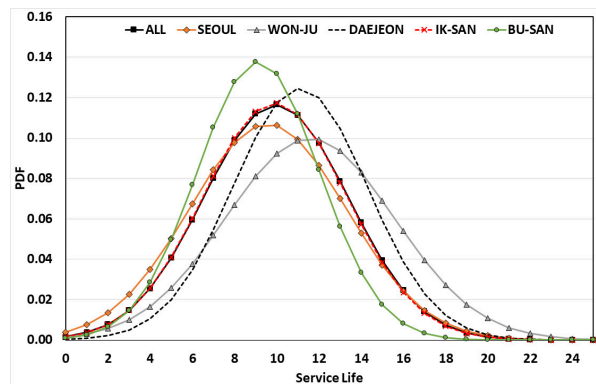


Fig. 4 Distribution of Data Set by Service Life

Table 1. Analysis of Data Set

Classification			N	Min	Max	Avg.	St dev.
Service life(year)		y	759	3.0	22.0	10.0	3.4
Traffic (million-veh/lane)	CAADT	x1		0.2	21.4	4.0	3.4
	CESAL	x2		0.0	6.1	0.5	0.5
Pavement thickness (cm)	Maintenance layer	x3		0.0	22.0	3.4	5.2
	Surface	x4		4.0	28.0	7.7	2.7
	Base	x5		7.0	25.0	16.7	4.5
	Subbase	x6		00	50.0	30.2	8.1
	Anti-frost layer	x7		0.0	75.0	15.1	17.7
	SNP	x8		3.1	8.6	4.9	0.7
Region		x9	Seoul, Daejeon, Iksan, Wonju, Busan				

모든 포장 구간의 평균 공용수명인 10.0년을 감안하면 익산청에 속한 포장구간의 평균 공용수명은 9.9년으로 가장 유사한 것으로 나타났으며, 부산청은 9.1년, 서울청은 9.6년으로 평균 대비 포장의 평균 공용수명이 짧은 것으로 나타났다. 반면, 대전청은 11.1년, 원주청은 11.6년으로 평균 대비 포장의 평균 공용수명이 긴 것으로 나타나 지역적인 특성에 따라 포장의 평균 공용수명이 달라짐을 알 수 있다. 이 외에 각 변수의 기초 통계는 Tabel 1과 같다.

4.2. 딥러닝 모델 구축

다중회귀분석의 경우 독립변수 간의 상관관계가 존재할 경우 회귀 계수의 분산이 커져 모델의 신뢰성 높은 추정치가 어렵기 때문에 분산팽창인수(VIF; Variance Inflation Factor), 공차 한계(Tolerance) 등의 지표를 통한 변수 제거를 통해 신뢰성 높은 모델을 추정해 왔다.

하지만 회귀분석의 범주 안에서 선택된 변수는 독립변수와 종속변수의 비선형 관계를 파악하는 딥러닝의 입력변수로는 적합하지 않기 때문에 상호정보량(MI; Mutual Information)기법, 부분상호정보량(PMI; Partial Mutual Information) 등의 기법들이 개발되어 변수 선정에 활용되고 있다(May et al., 2011; May et al., 2008; Bowden et al., 2005).

본 연구에서 딥러닝을 활용한 공용수명의 예측을 위해서 선정한 입력변수(x_1, x_2, \dots, x_9)의 경우 공용수명에 미치는 변수의 영향력 보다는 예측력 제고가 목적이기 때문에 입력층에 9개의 변수를 모두 활용하였으며 출력층에는 포장의 공용수명을 입력하였다. 분석데이터는 70%를 학습(training), 30%를 검증(test)을 위해 활용하였다.

일반적으로 딥러닝 모델을 구성하는 주요변수로 은닉층수, Hidden neuron수 등이 있으며 시행착오법과 같은 휴리스틱(Heuristic)한 기법을 통해 최적의 모델을 구성하게 된다. 따라서, 특정 데이터셋을 대상으로 최적의 모델을 구축하기 위해서는 다양한 변수들의 조합을 통해 최적의 설명력을 갖도록 모델을 구축해야 하므로 본 연구에서는 모델의 Hidden neuron수는 128개로 일정하게 유지하고 은닉층은 1개, 2개, 4개, 8개로 변동시켜가면서 최적의 성능을 보이는 구조를 찾고자 분석을 수행하였다.

나아가, 딥러닝 학습시에 발생할 수 있는 과적합(over fitting) 문제 해결의 적용성을 검증하기 위해 드롭아웃(dropout) 기법이 적용된 경우와 적용되지 않은 경우에 대한 시나리오 분석을 수행하였다. 드롭아웃 정

규화기법을 적용함에 있어서는 입력층에는 0.8, 은닉층에는 0.5의 계수(p)를 적용하였다. 여기서 0.8의 계수는 입력층에 존재하는 뉴런의 80%를 제외한 20%에 대해 드롭아웃기법을 적용함을 의미한다.

본 연구에서는 시뮬레이션을 수행함에 있어 DNN(Deep Neural Networks) 모델에 대한 활성화함수(activation function)중 가장 성능이 뛰어난 ELU함수를 활용하여 시뮬레이션을 수행하였으며 학습률(learning Rate)은 0.01, 학습을 위한 Epochs은 5,000회로 고정하였다. 또한, 비용함수(cost function)는 일반적으로 많이 적용되는 평균제곱오차(MSE; Mean Square Error)를 적용하였으며 분석 결과에 해당하는 정확도(accuracy)는 결정계수를 통해 나타낼 수 있도록 모델을 구성하였다(Eq. (5)).

$$R-squared = 1 - \frac{\sum_i (y_i - \hat{y}_i)^2}{\sum_i (y_i - \mu)^2} \quad (5)$$

여기서, y_i 는 실측 공용수명 값, \hat{y}_i 는 딥러닝에 의해 예측된 공용수명 값, μ 는 실측 공용수명의 평균 값, i 는 샘플 수를 의미한다.

Fig. 5는 앞서 서술한 은닉층이 4개인 경우의 DNN 모델소스코드 일부를 표현한 것으로 크게 데이터 셋의 입력 및 입력층의 구성형태 등을 나타내고 있다.

```

In [1]: import tensorflow as tf
import pandas as pd
import numpy as np

In [2]: DATA = pd.read_excel('data2.xlsx')
Y = DATA['Service Life']
X1 = DATA['CAADT']
X2 = DATA['CESAL']
X3 = DATA['Maintenance layer']
X4 = DATA['Surface']
X5 = DATA['Base']
X6 = DATA['Subbase']
X7 = DATA['Anti-frost layer']
X8 = DATA['SNP']
X9 = DATA['Region']

In [3]: x_data = pd.concat([X1, X2, X3, X4, X5, X6, X7, X8, X9], axis=1)
y_data = pd.concat([Y], axis=1)

In [4]: x1_data = np.array(x_data, dtype=np.float32)
y1_data = np.array(y_data, dtype=np.float32)

In [5]: x_train_data = np.array(x1_data[:532], dtype=np.float32)
y_train_data = np.array(y1_data[:532], dtype=np.float32)

In [6]: x_test_data = np.array(x1_data[532:], dtype=np.float32)
y_test_data = np.array(y1_data[532:], dtype=np.float32)

In [7]: X = tf.placeholder(tf.float32, shape=[None, 9])
y = tf.placeholder(tf.float32, shape=[None, 1])
keep_prob = tf.placeholder("float")

In [8]: W1 = tf.get_variable("W1", shape=[9, 128],
initializer=tf.contrib.layers.xavier_initializer())
b1 = tf.Variable(tf.random_normal([128]))
L1 = tf.nn.einsum('m,mat,ml', X, W1) + b1
L1 = tf.nn.dropout(L1, keep_prob=0.8)

```

Fig. 5 Example of Tensor Flow Source Code

4.3. 분석결과

Table 2의 분석결과를 정리하면 다음과 같다. 먼저, 드롭아웃(dropout) 정규화기법이 적용될 경우 효과적으로 과적합(over fitting)문제가 해소된 것으로 나타났다.

드롭아웃 기법이 적용되기 이전의 학습데이터 분석결과를 살펴보면 은닉층의 개수에 상관없이 0.95~0.99수준의 높은 결정계수를 갖는 것으로 나타났으나 검증데이터의 결정계수는 0.30~0.38수준으로 낮은 것으로 나타났다. 이는 학습시에 과적합문제가 발생하였음을 의미하며 학습데이터의 결정계수(정확도)가 매우 높음에도 불구하고 새로운(검증) 데이터에 대한 결정계수가 낮게 되어 해당 모델의 예측력은 매우 낮다고 할 수 있다.

반면 드롭아웃(dropout) 정규화 기법이 적용된 경우의 분석결과는 은닉층의 개수에 상관없이 학습데이터의 결정계수는 0.79~0.91수준으로 낮아졌으나 상대적으로 중요한 검증데이터의 결정계수가 학습데이터와 유사한 0.61~0.84 수준의 결정계수를 갖는 것으로 나타나 효과적으로 과적합 문제가 해결된 것으로 나타났다.

나아가, 은닉층의 개수에 따른 최적화 모델을 선정한 결과 8개의 은닉층으로 구성된 모델의 결정계수가 가장 높은 것으로 나타났다. 그러나 은닉층이 2개로 구성된 경우를 제외하고는 대부분 0.81~0.84수준의 유사한 결정계수를 갖는 것으로 나타나 대부분의 모델 구성에 있어 높은 결정계수를 갖는 것으로 나타났다. 이는 은닉층이 2개인 경우를 제외할 경우 은닉층을 1개, 4개, 8개로 갖도록 모델을 구성하여도 큰 차이가 없음을 의미한다.

이는 다중회귀분석기법을 통해 취득 가능한 결정계수(R-squared)가 0.5 이하임을 감안하면 본 연구에서 제안한 딥러닝 기법을 이용한 공용수명 예측의 활용 가능성을 확인할 수 있었다.

Table 2는 입력변수들이 전부 고려된 경우에 대한 분석결과인 반면 Fig. 6은 전체 입력변수 중 지역변수의 포함 유·무에 따른 모델의 성능변화를 살펴본 결과이다.

분석결과, 은닉층의 개수 및 데이터 셋의 유형에 상관없이 지역변수가 제외된 모든 경우의 결정계수가 상대

적으로 낮아 전체적인 모델의 설명력이 0.49~0.73수준으로 크게 감소하는 것으로 나타났다.

이는 Fig. 4에서도 알 수 있는 바와 같이 지역적인 특성을 고려하여 신경망 학습 모델을 구축하여 공용수명을 예측하는 것이 효율적임을 확인할 수 있었다.

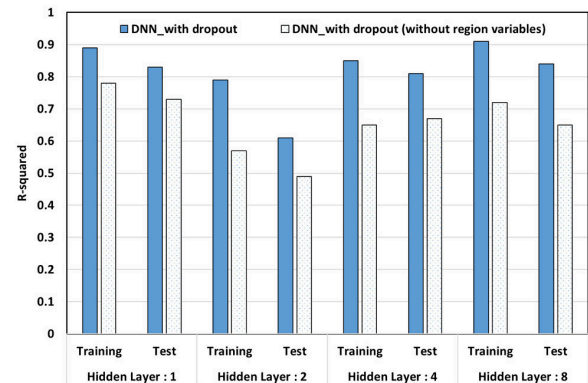


Fig. 6 Analysis Result of R-squared by Region Variable

5. 결론

본 연구에서는 일반국도 유지보수 내시구간(2012~2014년)의 유지보수이력 데이터를 활용하여 딥러닝 방법론을 통해 일반국도 아스팔트포장의 공용수명을 예측함과 동시에 활용가능성에 대해 검증해 보았다.

딥러닝 네트워크의 구성을 위해 딥러닝 프레임워크 중 오픈소스로서의 활용성이 뛰어난 Tensorflow 1.5를 활용하였다. 분석을 위해 입력데이터에는 누적교통량, 누적축하중, 보수층, 표층, 기층, 보조기층, 동상방지층, SNP, 지역관리청의 9가지 변수를 선정하였으며 출력데이터로는 공용수명을 선정하여 입력층과 출력층을 구성하였다. 또한 시나리오 분석을 위해 은닉층의 개수는 1개, 2개, 4개, 8개로 하여 모델을 구성하였으며 과적합 해소기법의 적용여부에 따른 시뮬레이션 분석을 수행하였다.

분석결과, 은닉층의 개수에 상관없이 드롭아웃(dropout)과 같은 과적합 해소기법이 적용될 경우 검증데이터에서의 결정계수가 높아져 공용수명의 예측력이

Table 2. Analysis Result of R-squared

	Hidden layer : 1		Hidden layer : 2		Hidden layer : 4		Hidden layer : 8	
	Training data	Test data	Training data	Test data	Training data	Test data	Training data	Test data
DNN_without dropout	0.95	n.a.	0.99	n.a.	0.98	0.38	0.97	0.30
DNN_with Dropout	0.89	0.83	0.79	0.61	0.85	0.81	0.91	0.84

향상됨을 확인하였다.

나아가, 지역변수의 적용유무에 따른 민감도 분석을 수행한 결과, 지역변수가 미포함된 경우의 결정계수는 최대 0.73, 지역변수가 포함된 경우에는 최대 0.84로 나타나 포장의 공용수명을 추정하는데 있어 지역적인 특성에 대한 충분한 고려가 이루어져야 함을 알 수 있었다.

지금까지 살펴본 바와 같이 교통, 포장구조, 지역적인 요인들의 고려를 통해 일반국도 포장구간에 대한 정확한 공용수명의 예측이 가능함을 살펴보았으며 이를 포장관리시스템에 접목할 경우 유지보수 시기 결정 등에 기초 자료로 활용할 수 있을 것으로 기대된다.

다만 본 연구에서는 입력변수를 교통 구조, 지역적 요인으로 한정하였다는 한계가 있으며, 모델의 구성에 있어서도 다양한 은닉층 개수, Hidden neuron 개수 및 학습률의 변화 등을 고려하지 못하였다는 한계가 있음을 밝힌다. 향후, 기상요인과 같은 다양한 입력변수를 고려한 시나리오 분석이 필요하다고 판단된다.

감사의 글

이 논문은 2017년도 한밭대학교 교내학술연구비의 지원을 받았습습니다.

REFERENCES

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.

Attoh-Okine, N. O. (1999). "Analysis of learning rate and momentum term in backpropagation neural network algorithm trained to predict pavement performance." *Advances in Engineering Software*, Vol.30, No.4, pp.291-302.

Baek, J., Lim, J., Kwon, S., and Kwon, B. (2015). "Performance Evaluation of Long-Life Asphalt Concrete Overlays Based on Field Survey Monitoring in National Highways." *Intl. Journal of the Highway Engineers*, Vol. 17, No. 3, pp.69-76.

Bowden, G.J., Dandy, G.C., Maier, H.R. (2005). "Input determination for neural network models in water resources applications. Part 1-background and methodology." *Journal of Hydrology*, Vol.301, No.1-4, pp.75-92.

Clevert, D. A., Unterthiner, T., Hochreiter, S. (2015). "Fast and accurate deep network learning by exponential linear units (elus)." arXiv preprint arXiv:1511.07289.

Dahl, G. E., Sainath, T. N., Hinton, G. E. (2013). "Improving deep neural networks for LVCSR using rectified linear units and dropout." IEEE International Conference Acoustics on Speech and Signal Processing(ICASSP), pp.8609-8613.

Do, M. and Kwon, S. (2010). "Selection of Probability Distribution

of Pavement Life Based on Reliability Method." *Intl. Journal of the Highway Engineers*, Vol.12, No.1. pp.61-69.

Gopalakrishnan, K., Khaitan, S. K., Choudhary, A., Agrawal, A. (2017). "Deep Convolutional Neural Networks with transfer learning for computer vision-based data-driven pavement distress detection." *Construction and Building Materials*, Vol.157, pp.322-330.

Han, D., Yoo, I., 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*, Vol.19, No.4, pp.1-7.

Han, D., Do, M., Kim, B. (2017b). "Internal Property and Stochastic Deterioration Modeling of Total Pavement Condition Index for Transportation Asset Management." *Intl. Journal of the Highway Engineers*, Vol.19, No.5, pp.1-11.

Han, D. (2013). "Stochastic Disaggregation and Aggregation of Localized Uncertainty in Pavement Deterioration Process." *Journal Of The Korean Society Of Civil Engineers*, Vol.33, No.4. pp.1651-1664.

Han, D. and Do, M. (2012). "Estimation of Life Expectancy and Budget Demands based on Maintenance Strategy." *Journal Of The Korean Society Of Civil Engineers*, Vol.32, No.4D, pp.345-356.

Hinton, G. E., Osindero, S., Tech, Y. W. (2006). "A fast learning algorithm for deep belief nets." *Neural computation*, Vol.18, No.7, pp.1527-1554.

Kim, H., and Lim, H. (2016). "A Basic Study on the Prediction of Collapse of Tunnels Using Artificial Neural Network." *Journal of The Korean Geotechnical Society*, Vol.32, No.2, pp.5-17

Kobayashi, K., Kaito, K., Nam, L. (2012). "A statistical deterioration forecasting method using hidden Markov model with measurement error." *Transportation Research-Part B*, Vol.46, pp.544-561.

Kobayashi, K., Do, M., Han, D. (2010). "Estimation of Markovian transition probabilities for pavement deterioration forecasting." *KSCE J. of Civil Engineering*, Vol.14, No.3, pp.341-351.

Ministry of Land, Infrastructure, and Transport (MOLIT) (2016). Development of Road Asset Management System Focus on Road Pavement.

May, R., Dandy, G., and Maier, H. (2011). "Review of Input Variable Selection Methods for Artificial Neural Networks." *Artificial Neural Networks-Methodological Advances and Biomedical Applications*, Edited by Suzuki, K., InTech, India, pp.19-44.

May, R.J., Maier, H.R., Dandy, G.C., Fernando, T.M.K.G. (2008). "Non-linear variable selection for artificial neural networks using partial mutual information." *Environmental Modelling & Software*, Vol.23, No.10-11, pp. 1312-1326.

Mishalani, R.G., and Madanat, S.M. (2002). "Computation of

- infrastructure transition probabilities using stochastic duration models." *J. of Infrastructure Systems*, Vol.8, No.4, pp.139-148.
- Minsky M.L., Papert, S. A. (1969). "*Perceptrons*." Cambridge, MA: MIT Press.
- Nair, V., Hinton, G. E. (2010). "Rectified linear units improve restricted boltzmann machines." *In Proceedings of the 27th International on Machine Learning (ICML-10)*, pp.809-814.
- Srivastava N., Hinton, G. E., Krizhevsky, A., Sutskever, I., Salakhutdinov, R. (2014). "Dropout: A simple way to prevent neural networks from overfitting." *The Journal of Machine Learning Research*, Vol.15, No.1, pp.1929-1958.
- Tan, P.N., Steinbach, M., Kumar, V. (2006). "Introduction to Data Mining", Pearson Education, Addison Wesley.
- Terzi, S. (2007). "Modeling the pavement serviceability ratio of flexible highway pavements by artificial neural networks." *Construction and Building Materials*, Vol.21, No.3, pp.590-593.
- Werbos, P.J. (1974). "*Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences*." PhD thesis, Harvard University.