

## 심층신경망을 이용한 비운송 지중구조물의 탄산화속도 예측 모델링

윤병돈  
(주)플랜올이엔씨 연구개발부문

### Modelling on the Carbonation Rate Prediction of Non-Transport Underground Infrastructures Using Deep Neural Network

Byong-Don Youn  
Division of R & D, PLANALL Engineering & Construction Inc.

**요약** 비운송 지중구조물인 전력구와 공동구는 대부분 철근 콘크리트 구조물로서 공용기간이 경과함에 따라 탄산화에 의한 열화로 내구성이 저하된다. 특히, 전력구 및 공동구는 용도별, 지역별로 탄산화 속도가 상이하므로 개별적인 유지관리를 위해서는 탄산화 실측 데이터에 기반한 예측 모델이 요구된다. 본 연구에서는 노후화 된 전력구 및 공동구와 같이 기존 비운송 지중구조물에 대한 탄산화 예측 모델을 개발하였다. 탄산화 예측 모델 개발을 위해 안전점검에서 확보한 실측 데이터를 기반으로 다중회귀분석 및 심층신경망 기법을 활용하였다. 다중회귀분석에서 종속 변수인 탄산화 속도 계수 결정을 위해 독립 변수로서 구조물, 지역, 측정 위치, 시공 유형, 측정 부재, 콘크리트 강도를 선정하였으며, 다중회귀 예측 모델의 수정결정계수( $R_a^2$ )는 0.67로 분석되었다. 심층신경망을 이용한 비운송 지중구조물의 탄산화 예측 모델 결정계수( $R^2$ )는 0.82로 나타났으며, 비교대상 모델보다 우수한 예측 성능을 보였다. 심층신경망을 이용한 비운송 지중구조물의 탄산화 예측 모델은 콘크리트 강도에 기초한 것으로, 본 연구의 결과가 노후화 된 전력구 및 공동구에 대한 탄산화 유지보수 최적 시기 결정 및 예방적 유지관리 방법론에 기여되길 기대한다.

**Abstract** PCT (Power Cable Tunnel) and UT (Utility Tunnel), which are non-transport underground infrastructures, are mostly RC (Reinforced Concrete) structures, and their durability decreases due to the deterioration caused by carbonation over time. In particular, since the rate of carbonation varies by use and region, a predictive model based on actual carbonation data is required for individual maintenance. In this study, a carbonation prediction model was developed for non-transport underground infrastructures, such as PCT and UT. A carbonation prediction model was developed using multiple regression analysis and deep neural network techniques based on the actual data obtained from a safety inspection. The structures, region, measurement location, construction method, measurement member, and concrete strength were selected as independent variables to determine the dependent variable carbonation rate coefficient in multiple regression analysis. The adjusted coefficient of determination ( $R_a^2$ ) of the multiple regression model was found to be 0.67. The coefficient of determination ( $R^2$ ) of the model for predicting the carbonation of non-transport underground infrastructures using a deep neural network was 0.82, which was superior to the comparative prediction model. These results are expected to help determine the optimal timing for repair on carbonation and preventive maintenance methodology for PCT and UT.

**Keywords** : Carbonation Rate, Deep Neural Network, Multiple Regression, Power Cable Tunnel, Utility Tunnel

\*Corresponding Author : Byong-Don Youn(PLANALL E & C Inc.)

email: twowit@naver.com

Received January 4, 2021

Accepted April 2, 2021

Revised January 25, 2021

Published April 30, 2021

## 1. 서론

도로, 철도, 항만 등으로 대표되는 사회기반시설물 중 전력구(PCT: Power Cable Tunnel), 공동구(UT: Utility Tunnel)와 같이 우리가 자주 간과하는 비운송 지중구조물(non-transport underground infrastructures)이 있다. 전력구와 공동구는 대부분 철근 콘크리트 구조물로서 공용기간이 경과함에 따라 균열, 누수, 백태 등의 손상이 발생되어 열화의 증가와 함께 내구성이 저하된다. 2018년 기준으로 국내 사회기반시설물의 유지보수 규모는 연간 약 6조원이 소요되는 것으로 보고되었으며, 사회기반시설물 노후도 조사 결과 30년 이상 공용중인 전력구 및 공동구는 각각 10%, 25% 수준으로서 공용기간을 20년 이상으로 설정하는 경우 전력구는 34%, 공동구는 43%를 점유하는 것으로 나타났다[1]. 이에 따라 구조물에 대한 유지보수 비용은 지속적으로 증가하고 있는 실정이며, 특히 전력구와 공동구는 도심지의 지중구조물로서 내구수명 종료 후에도 해체 및 폐기가 용이하지 않기 때문에 구조물의 수명주기 동안 효율적인 유지관리가 요구된다.

선행 연구에 의하면 전력구 및 공동구와 같은 지중구조물의 내구성 저하는 탄산화, 염해, 화학적 침식 등에 기인하는 것으로 나타났으며, 그 중 탄산화가 내구성 저하의 주요 원인으로 지목되었다[2-4]. 즉, 탄산화 진행을 예측하는 것은 전력구 및 공동구의 내구수명을 평가하는 핵심 과정이다. 일반적으로 탄산화는 콘크리트 배합 설계, 시공 품질과 같은 내부 요인과 CO<sub>2</sub> 농도, 온도, 강수 빈도, 일사량, 습도 등과 같은 외부 요인에 의해 영향을 받는다[5]. 구조물의 내구수명을 예측하기 위해 많은 연구자들은 실내 실험과 노출 실험 등을 통해 시간 경과에 따른 탄산화 예측 모델을 제안하였다[6]. 큰 범주에서 볼 때, 제안된 모델들은 탄산화 속도의 영향 인자로서 물-결합재비(W/B: Water-Binder Ratio, 이하 W/B), 투기성(permeability), CO<sub>2</sub> 확산(CO<sub>2</sub> diffusion), 콘크리트 강도(concrete strength) 등에 기초하고 있다[7]. 그러나 연구자들 사이에 탄산화 속도를 고려하는 매개변수가 상이하여 제안된 탄산화 예측 모델들은 구조물의 사용수명 동안 탄산화 예측 깊이에 차이가 필연적으로 발생한다. 또한, 고전적인 탄산화 예측 모델들은 시멘트 종류, 골재 및 혼화재의 종류, 콘크리트 양생 조건 등과 같은 건설 정보가 있는 경우 합리적인 적용이 가능하지만, 20년 이상 공용중인 전력구 및 공동구에 대하여 이와 같은 건설 정보를 확보하는 것은 현실적으로 불가능하다.

현재 국내의 주요 사회기반시설물은 육안조사, 비파괴 검사 등에 기초한 시설물 안전점검을 통해 유지관리되고 있으며, 이와 같은 안전점검 결과로부터 확보된 다양한 실측 데이터를 바탕으로 콘크리트의 탄산화를 예측하기 위한 연구가 진행되고 있다. 그러나 대부분의 연구가 교량, 도로 터널, 철도 터널 및 지하철과 같은 운송 사회기반시설물에 대해 수행되었다[8-11]. 전력구 및 공동구와 같은 비운송 지중구조물은 운송 사회기반시설물과 사용 목적 및 운영 환경 등이 상이하여 CO<sub>2</sub> 농도, 온도, 습도 등과 같은 요인에 기인한 콘크리트 탄산화 진행 속도에도 차이가 예상된다. 특히, 비운송 지중구조물의 경우에도 환기성능에 의해 전력구 및 공동구의 용도별, 지역별로 탄산화 속도가 상이한 것으로 나타났으며[12], 따라서 전력구와 공동구에 대한 탄산화 진행을 용도 및 지역별로 개별 관리하기 위해서는 탄산화 실측 데이터에 기반한 새로운 유형의 탄산화 예측 모델이 요구된다.

본 연구에서는 노후화 된 전력구 및 공동구와 같이 기존 비운송 지중구조물에 대한 탄산화 예측 모델을 개발하였다. 모델 개발을 위해 전력구 및 공동구에 대하여 정기적으로 수행되는 시설물 안전점검에서 제공된 실측 데이터를 활용하였다. 탄산화 인자와 탄산화 속도 계수의 관계를 선형 모형으로 해석한 다중회귀 모델을 제시하였으며, 비선형 모형에 대한 추론이 가능한 심층신경망 기반 회귀 모델을 최종적으로 개발하였다. 본 연구의 결과가 노후화 된 전력구 및 공동구에 대한 탄산화 유지보수 최적 시기 결정 및 예방적 유지관리 방법론에 기여되길 기대한다.

## 2. 본론

### 2.1 선행연구 고찰

종래에 탄산화의 깊이가 탄산화 기간의 제곱근에 비례하는 것이 입증되었으며, 공기 중의 CO<sub>2</sub>에 의한 콘크리트 표면에서의 탄산화 진행은 Eq. (1)과 같이 노출 시간의 함수로 표현된다[6,13]. 탄산화 예측 모델 Eq. (1)의 탄산화 속도 계수(carbonation rate coefficient)는 W/B, 콘크리트 강도, 혼화재 및 시멘트 유형, 경화 정도, 대기 중 CO<sub>2</sub> 농도, 온도, 습도 등의 요인에 따라 통계적 회귀분석 등을 통해 실험적으로 결정된다.

$$y = b\sqrt{t} \quad (1)$$

Where,  $y$  denotes carbonation depth in concrete  $b$  denotes carbonation rate coefficient of concrete  $t$  denotes exposed time in the air.

반면에 탄산화 예측에 대한 새로운 기법은 기계학습(machine learning) 및 신경망(neural network)과 같은 인공지능(artificial intelligence) 기술을 기반으로 한다. 인공지능 기반 예측 모델에서는 데이터를 이용한 단순 통계나 저차원 회귀 분석이 아닌 비선형 모형의 추론이 가능한 알고리즘을 사용하기 때문에 종래의 탄산화 예측 모델보다 상대적으로 양호한 예측 성능을 기대할 수 있다. 특히, 딥 러닝(deep learning) 기법을 활용한 탄산화 예측 연구가 수행되었다[14-17]. 딥 러닝은 컴퓨터가 데이터에서 학습하도록 가르치는 기계학습 기법이며, 대부분의 딥 러닝은 다층의 인공신경망(artificial neural network)을 사용함으로써 심층신경망(deep neural network) 모델로도 알려져 있다.

이러한 심층신경망 기반 모델의 경우, 높은 예측 신뢰성을 확보하기 위해서는 콘크리트의 탄산화에 영향을 미치는 다양한 요인에 대한 체계적인 데이터가 요구된다. 그러나, 선행된 딥 러닝 기법을 활용한 연구에서는 탄산화 예측을 위한 예측 변수(feature)로서 종래의 탄산화 예측 모델에서 다루었던 시멘트량, 상대 습도, 고로슬래그 및 플라이애쉬 혼입량, 혼화재 혼입 여부, 골재 치수, W/B 등의 건설 정보를 고려하고 있다. 따라서 기존에 수행되었던 딥 러닝 기법을 활용한 탄산화 예측 모델을 전력구 및 공동구와 같이 각종 건설 정보가 망실된 지중구조물에 직접 적용하는 것은 용이하지 않다.

## 2.2 데이터 수집 및 분석

전력구 및 공동구에 대한 탄산화 예측 모델 개발을 위하여 국내 6개 주요 지역에서 수행된 시설물 안전점검 및 정밀점검 결과로부터 탄산화 관련 데이터를 수집하였다. 구조물의 기본 사양으로서 크기, 시공방법, 건설연도 및 공용기간 등을 조사하였다. 또한, 비파괴검사 데이터로서 콘크리트 반발경도 및 추정 압축강도, 탄산화 깊이, 철근 피복 두께 등을 수집하였다. 수집된 1,497 세트의 데이터 현황은 Table 1 및 Fig. 1과 같다.

Table 1. Data collection status on PCT and UT by region

Structures & Region	Span Lengths (km)	Year of Construction	Year of Inspection	Num. of Data (set)	
PCT	Seoul	8.488	1987 ~ 2008	2017	297
	Incheon	19.441	1978 ~ 1998	2017	54
	Daejeon	11.092	1993 ~ 2002	2018	59
	Daegu	37.848	1985 ~ 2016	2017	229
	Gwangju	24.926	1987 ~ 2015	2017	217
	Busan	41.604	1982 ~ 2009	2018	148
UT	Seoul	39.040	1978 ~ 2003	2017	159
	Incheon	27.562	1992 ~ 2014	2017 ~ 2019	114
	Daejeon	21.671	1994 ~ 2016	2016, 2018	77
	Daegu	6.945	1979 ~ 1983	2017, 2019	38
	Gwangju	1.797	1998	2015, 2017	46
	Busan	7.270	1996	2016, 2018	59

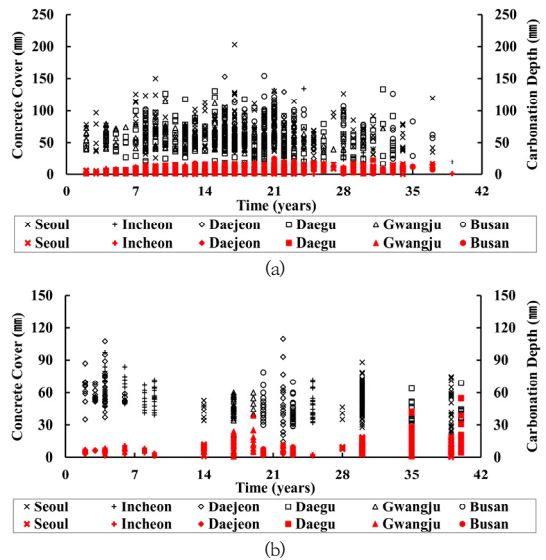


Fig. 1. Carbonation and cover depth on PCT and UT  
(a) PCT (b) UT

수집된 비파괴검사 데이터는 전력구 및 공동구의 내면에 대한 검사 결과로서 지중구조물의 특성을 고려할 때 외면에 대한 검사는 불가능하지만, 일반적으로 탄산화에 의한 콘크리트의 내구성 저하는 전력구 및 공동구의 외면보다 외기에 노출된 내면에서 더 빠르기 때문에 수집된 비파괴검사 데이터는 해당 구조물의 탄산화 열화도(deterioration degree)를 대표할 수 있을 것으로 판단된다.

### 2.3 다중회귀분석을 이용한 탄산화 모델링

#### 2.3.1 변수 선정 및 회귀 분석

전력구 및 공동구의 탄산화 예측 모델에 대한 종속 변수로서 탄산화 속도 계수(crc)를 결정하기 위해 모든 가능한 회귀법을 활용한 변수선택법을 적용하였다. 수집된 1,497 세트의 실측 데이터에 근거하여 Table 2와 같이 선정된 독립 변수 중 구조물(structures), 지역(region), 측정 위치(location)의 변수들은 탄산화의 외부 요인으로서 CO<sub>2</sub> 농도 및 습도 등과 관련이 있다. 시공 유형(type), 측정 부재(member), 콘크리트 강도(strength)는 탄산화의 내부 요인으로서 시공 품질, 콘크리트 재질 및 배합 등에 연관된 변수이다. 독립 변수 선택을 위한 판정기준으로서 결정계수(R<sup>2</sup>), 수정결정계수(R<sub>a</sub><sup>2</sup>), C<sub>p</sub> 통계량, AIC 통계량을 검토하였으며, 각각의 분석 결과는 Table 3과 같다.

Table 2. Variables of the multiple regression model

Variable	Definition	Values
structures	Classification of structures	•0 = PCT •1 = UT
region	Region classification of structures	•0 = Seoul •1 = Incheon (region <sub>1</sub> ) •2 = Daejeon (region <sub>2</sub> ) •3 = Daegu (region <sub>3</sub> ) •4 = Gwangju (region <sub>4</sub> ) •5 = Busan (regions)
type	Construction method of structures	•0 = Cast-in-Place RC •1 = Precast concrete
location	Measurement location of structures	•0 = Wall •1 = Slab
member	Measurement member of structures	•0 = Tunnel •1 = Shaft
strength	Compressive strength of concrete	•Range: 17.5 ~ 57.5 •Unit: MPa
crc	Carbonation rate coefficient	•Range: 0.017 ~ 8.807 •Unit: mm/√year

Table 3. Variables selection by all possible regression

Variable	Num. of Var.	R <sup>2</sup>	R <sub>a</sub> <sup>2</sup>	C <sub>p</sub>	AIC
structures/ region <sub>1</sub> / region <sub>2</sub> / region <sub>3</sub> / region <sub>4</sub> / region <sub>5</sub> / type/ location/ member/ strength	10	0.673	0.670	11.00	-1029

오픈소스 기반 통계분석 프로그램 R(Ver. 3.6.1)을 활용하여 Table 1의 데이터 1,497 세트에 대해 분석을 수

행하였다. 다중선형회귀 모델의 수정결정계수(R<sub>a</sub><sup>2</sup>)는 0.67로 나타났다.

#### 2.3.2 회귀 모형 추정 및 진단

전력구 및 공동구의 탄산화 예측을 위한 다중회귀 모델은 Eq. (2)와 같다. 최소제곱법에 의한 회귀계수 (Regression Coefficient) β의 추정 결과는 Table 4와 같으며, 추정된 회귀계수는 각각의 신뢰구간을 만족시키는 것으로 나타났다.

$$crc = \beta_0 + \beta_1 structures + \beta_2 region_i + \beta_3 type + \beta_4 location + \beta_5 member + \beta_6 strength$$

Table 4. Confidence intervals of regression coefficients

Variable	Regression Coefficient	Confidence Interval	
		2.5 %	97.5 %
(Intercept)	4.116421	3.8000666	4.43277620
structures	0.42880	0.3440046	0.51360072
region <sub>1</sub>	-0.16558	-0.3014634	-0.02968991
region <sub>2</sub>	0.40984	0.2718828	0.54780064
region <sub>3</sub>	0.61959	0.5106527	0.72852342
region <sub>4</sub>	0.38698	0.2727017	0.50125423
region <sub>5</sub>	0.25067	0.1330210	0.36832666
type	1.58142	1.3305292	1.83230543
location	-0.01485	-0.1244387	0.09473149
member	1.52421	1.4414190	1.60699156
strength	-0.11713	-0.1280466	-0.10621388

추정된 회귀 모형의 유의성을 판단하기 위하여 분산분석(ANOVA: Analysis of Variance)을 수행하였다. Table 5에서와 같이 F-검정에 의한 통계량은 305.150 이고, P-값 < α = 0.05로서 추정된 회귀 모형은 통계적으로 유의한 것으로 판단된다. Table 6의 분산팽창인자 (VIF: Variance Inflation Factor)에 의한 다중공선성 진단결과, 독립 변수들간의 종속관계는 존재하지 않는 것으로 나타났다.

Table 5. ANOVA on the multiple regression model

-	Sum Sq	Df	Mean Sq	F value	Pr (>F)
Regression	1523.146	10	152.315	305.150	< 0.0001
Residuals	741.731	1486	0.499		
Sum	2264.877	1496			

Table 6. VIF on the multiple regression model

Variable	VIF	Variable	VIF
structures	1.2379	region5	1.2856
region1	1.4340	type	1.6145
region2	1.2253	location	1.1779
region3	1.3555	member	1.2258
region4	1.4741	strength	1.8765




Fig. 2. Residual analysis on the multiple regression model

(a) Residuals vs Fitted (b) Normal Q-Q  
(c) Scale-Location (d) Residuals vs Leverage

추정된 회귀 모델의 오차항 등분산성, 독립성, 선형성, 정규성 등에 대한 가정의 타당성을 검증하기 위하여 잔차분석(residual analysis)을 수행하였다. Fig. 2에서와 같이 잔차분석 결과, 추정된 회귀 모형은 기본 가정을 충족하는 것으로 나타났다.

## 2.4 심층신경망을 이용한 탄산화 모델링

### 2.4.1 인공신경망 및 심층신경망

인공신경망은 인간의 신경정보 교환을 Fig. 3 및 Eq. (3)에서와 같이 수학적 모델링으로 구현한 기계학습 알고리즘으로서 딥 러닝의 심층신경망은 인공신경망 구조를 보다 다층화하여 활용하는 기술이다.




Fig. 3. Processing unit of biological and ANN[18]

$$y(x) = f\left(\sum_{i=1}^n w_i x_i + b_i\right) \quad (3)$$

Where,  $w_i$  denotes weights  $x_i$  denotes inputs  $b_i$  denotes bias.

일반적으로 심층신경망과 같이 인공신경망을 다층화하는 경우, 은닉층(hidden layer)의 활성화 함수(activation function)에 의해 비선형 모형에 대한 추론이 가능하다 [18].

### 2.4.2 심층신경망 모델링

전력구 및 공동구의 탄산화 예측을 위한 모델링을 위하여 Table 7에서와 같이 4 종의 심층신경망 모델을 가정하였다. 입력층(input layer)의 예측 변수(feature)와 출력층(output layer)의 반응(label)은 각각 Table 2의 독립 변수 및 종속 변수와 동일하다. 심층신경망을 이용한 탄산화 예측 모델링을 위해 Table 2에 제시된 데이터는 평균과 표준편차를 활용한 Z-Score 표준화(Z-Score standardization)에 의해 정규화하였다[19].

전체 데이터는 단순 유보 검증(simple hold-out validation) 기법에 따라 80:20의 비율을 적용하여 훈련 세트와 시험 세트로 구분하고 훈련 세트는 다시 동일한 비율에 따라 훈련 세트와 검증 세트로 분리하였다. 모델링에 사용된 딥 러닝 라이브러리는 케라스(Keras)를 활용하였으며, 모델의 과적합(overfitting)을 방지하기 위해 드롭아웃(dropout) 학습 기법을 도입하였다[20]. 모델링의 세부 조건은 Table 8과 같다.

Table 7. Architecture of deep neural network models

Model	Hidden Layer (ea.)	Node (ea.)
DNN_3H	3	9-5-3
DNN_4H	4	15-9-5-3
DNN_5H	5	20-15-9-5-3
DNN_6H	6	25-20-15-9-5-3

Table 8. Modelling condition of the DNN model

Condition	Deep Neural Network
Training Algorithm	Error Backpropagation
Activation Function	Rectified Linear Unit (ReLU)
Loss Function	Mean Squared Error (MSE)
Optimizer	AdaMax
Learning Rate	0.001
Epoch	5000
Batch Size	12

Table 9. Metrics results of the DNN models

Model	Metrics			
	MSE (mm/√year) <sup>2</sup>	MAE (mm/√year)	RMSE (mm/√year)	R <sup>2</sup>
DNN_3H	0.4718	0.4798	0.6869	0.7471
DNN_4H	0.4406	0.4557	0.6638	0.7638
DNN_5H	0.3269	0.3763	0.0571	0.8248
DNN_6H	0.4492	0.4184	0.6702	0.7592

평균제곱오차(MSE), 평균절대오차(MAE), 평균제곱근 오차(RMSE), 결정계수(R<sup>2</sup>)는 기계학습 모델의 성능을 평가하는 주요 지표이다[21]. 전력구 및 공동구의 탄산화 예측을 위해 가졌던 모델들에 대한 성능평가 결과는 Table 9와 같다. DNN\_5H의 예측 성능이 가장 우수한 것으로 나타났으며, 특히 결정계수는 0.82로 나타났다. 따라서 본 연구에서 제안하는 심층신경망을 이용한 비운송 지중구조물의 탄산화 예측 모델은 5-은닉층의 DNN\_5H로 선정하였다.

### 2.5 기존 모델과 제안 모델의 성능 비교

비운송 지중구조물의 탄산화 예측을 위해 다중회귀분석을 이용한 모델(MLRM: Multiple Linear Regression Model, 이하 MLRM)과 심층신경망을 이용한 모델(DNNM: Deep Neural Network Model, 이하 DNNM)을 제안하였다. Fig. 4 및 Fig. 5에서와 같이 제안된 모델의 탄산화 예측 성능에 대한 타당성을 평가하기 위하여 Eq. (4)의 한국콘크리트학회(KCI: Korea Concrete Institute, 이하 KCI) 시방 모델과 비교하였다[22]. 이 때, Eq. (4)의 W/B는 직접적인 실측 데이터가 없는 관계로 JASS 5의 Eq. (5)로부터 유도하였다[23].

$$y = R(-3.57 + 9.0W/B)\sqrt{t} \quad (4)$$

Where,  $y$  denotes carbonation depth  $W/B$  denotes effective water-binder ratio  $t$  denotes exposed

time in the air  $R$  denotes environmental condition coefficient

$$W/C = 61/(f/K+0.34) \quad (5)$$

Where,  $W/C$  denotes water-cement ratio  $f$  denotes compressive strength of concrete  $K$  denotes cement strength

Fig. 4, Fig. 5에서와 같이 지역별로 DNNM의 전력구 및 공동구에 대한 탄산화 예측 성능은 각각 결정계수(R<sup>2</sup>) 0.72 ~ 0.86, 0.76 ~ 0.91로서 회귀분석 기반의 다른 모델보다 우수한 것으로 나타났다. 이와 같이, 선형해석 기반의 MLRM과 활성화 함수 ReLU의 적용에 의해 비선형 모형에 대한 추론이 가능한 DNNM은 동일한 변수 적용 및 데이터를 대상으로 개발되었으나 결정계수(R<sup>2</sup>)는 각각 0.67, 0.82로서, DNNM은 탄산화 속도 예측을 위해 변수간의 상관관계를 비선형적으로 모델링함으로써 개선된 설명력을 보인 것으로 판단된다.

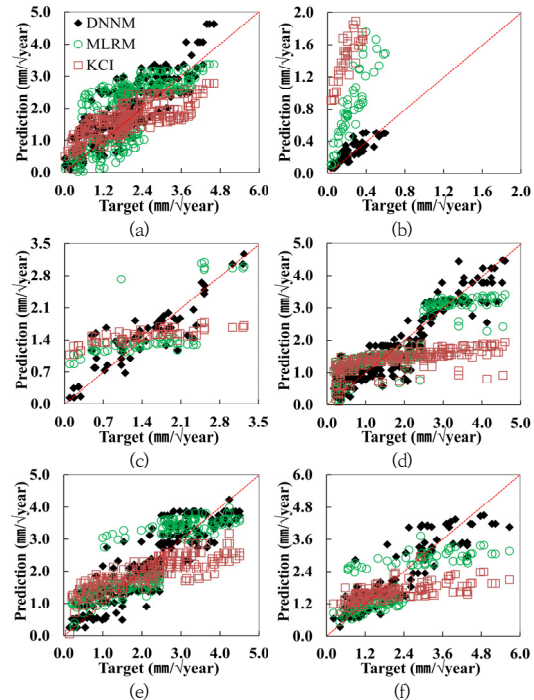


Fig. 4. Comparison results of proposed models for PCT  
(a) Seoul (b) Incheon (c) Daejeon (d) Daegu  
(e) Gwangju (f) Busan

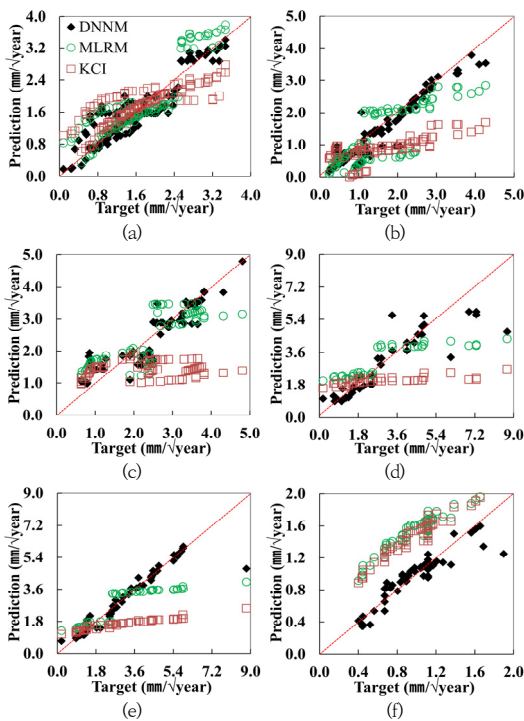


Fig. 5. Comparison results of proposed models for UT  
 (a) Seoul (b) Incheon (c) Daejeon (d) Daegu  
 (e) Gwangju (f) Busan

### 3. 결론

노후화 된 전력구 및 공동구와 같이 비운송 지중구조물에 대한 탄산화 예측 모델을 개발하였다. 모델 개발을 위해 안전점검에서 확보한 실측 데이터를 기반으로 다중회귀분석 및 심층신경망 기법을 활용하였으며, 도출된 결론은 다음과 같다.

- 1) 다중회귀분석에서 종속 변수인 탄산화 속도 계수 결정을 위해 독립 변수로서 구조물, 지역, 측정 위치, 시공 유형, 측정 부재, 콘크리트 강도를 선정하였으며, 개발된 다중회귀 예측 모델의 수정결정계수( $R_a^2$ )는 0.67로 분석되었다.
- 2) 심층신경망을 이용한 비운송 지중구조물의 탄산화 예측 모델로서 입력층, 5-은닉층, 출력층으로 구성된 DNN\_5H를 제안하였으며, 모델의 결정계수 ( $R^2$ )는 0.82로서 비교대상 모델보다 우수한 예측 성능을 보였다.
- 3) 본 연구에서 제안된 심층신경망을 이용한 비운송 지중구조물의 탄산화 예측 모델은 콘크리트 강도

에 기초한 것으로서, 선정된 예측 변수들은 지중구조물에 대하여 용도 및 지역별로 탄산화를 예측하는 것에 유효한 것으로 판단된다.

- 4) 심층신경망을 이용한 예측 모델의 경우, 선형해석에 기반한 다중회귀 예측 모델에 비교하여 탄산화 속도 추정을 위한 예측 변수들과 반응 사이의 상관관계를 비선형적으로 추론함으로써 보다 개선된 설명력을 확보한 것으로 사료된다.
- 5) 제안된 심층신경망 기반의 탄산화 예측 모델은 모델 개발시 데이터를 제공한 전력구 및 공동구에 대해서만 적절한 탄산화 예측 결과를 제시하지만, 노후화 된 비운송 지중구조물에 대한 탄산화 최적 유지보수 시기 결정 및 예방적 유지관리 방법론에 활용될 수 있을 것으로 기대된다.

### References

- [1] Ministry of Culture, Sports and Tourism. Republic of Korea, Comprehensive measures to strengthen the safety of sustainable infrastructure [Internet]. Ministry of Culture, Sports and Tourism. Republic of Korea, c2019 [cited 2019 Jun. 18]. Available From: <http://www.korea.kr/news/policyBriefingView.do?newsId=156336845> (accessed Dec. 16, 2020)
- [2] KEPRI, Development of Integrated Life Management System for Underground Structures based on LCC (Life Cycle Cost), Korea Electric Power Corporation, Korea, pp.312-327.
- [3] Y. Lee, J. R. Lee, S. K. Woo, J. E. Nam, "Service life estimation of concrete box culvert for power transmission", *Proceedings of the Korea Institute for Structural Maintenance and Inspection*, Jeju, Korea, pp.474-475, Oct. 2014.
- [4] J. H. Seong, Y. S. Lee, E. S. Hong, Y. S. Byun, "Development of performance assessment criterion for structures of shield TBM tunnel", *Journal of Korean Tunnelling and Underground Space Association*, Vol.17, No.5, pp.553-561, 2015. DOI: <http://dx.doi.org/10.9711/KTAJ.2015.17.5.553>
- [5] L. Czarnecki, P. Woyciechowski, "Modelling of concrete carbonation: is it a process unlimited in time and restricted in space?", *Bulletin of the Polish Academy of Science Technical Sciences*, Vol.63, No.1, pp.43-54, 2015. DOI: <http://dx.doi.org/10.1515/bpasts-2015-0006>
- [6] Alberto A. Sagués, Carbonation in Concrete and Effect on Steel Corrosion, WPI 0510685, Final Report, State Job 99700-3530-119, University of South Florida, College of Engineering, USA, pp.174-190.

- [7] S. O. Ekolu, "Towards practical carbonation prediction and modelling for service life design of reinforced concrete structures", *2015 IOP Conf. Ser.: Mater. Sci. Eng.*, Riga, Latvia, Vol.96, 30th Sep. to 2nd Oct., 2015.  
DOI: <http://dx.doi.org/10.1088/1757-899X/96/1/012065>
- [8] H. K. Kim, S. B. Kim, "Service life prediction and carbonation of bridge structures according to environmental conditions", *Journal of the Korea Institute for Structural Maintenance and Inspection*, Vol.14, No.4, pp.126-132, 2010.  
DOI: <https://doi.org/10.11112/jksmi.2010.14.4.126>
- [9] S. W. Cho, C. S. Lee, "A proposal of durability prediction models and development of effective tunnel maintenance method through field application", *Journal of the Korea Institute for Structural Maintenance and Inspection*, Vol.16, No.5, pp.148-160, 2012.  
DOI: <https://doi.org/10.11112/jksmi.2012.16.5.148>
- [10] T. K. Noh, Y. S. Shin, M. H. Go, H. S. Ryu, "Correlation analysis of compressive strength and carbonation depth in urban road tunnel", *Proceedings of the Korea Institute for Structural Maintenance and Inspection*, Busan, Korea, pp.57-85, Apr. 2015.
- [11] C. S. Lee, Y. O. Kim, Y. H. Kim, "Probabilistic approach of carbonation speed of subway concrete structures", *Proceedings of the Korean Society of Civil Engineers*, Daejeon, Korea, pp.1468-1471, Oct. 2008.
- [12] B. D. Youn, H. Hamada, "Probabilistic approach on the Carbonation Rate of Non-Transport Underground Infrastructures", *Advances in Construction Materials Proceedings of the Conmat'20, Sixth International Conference on Construction Materials*, Fukuoka, Japan, pp.290-299, Aug. 2020.
- [13] JSCE, Standard Specification for Concrete Structures - 2007; Maintenance, p.278, Japan Society of Civil Engineering, 2007, pp.110-112.
- [14] W. Z. Taffese, F. Al-Neshawy, E. Sistonen, M. Ferreira, "Optimized neural network based carbonation prediction model", *International Symposium Non-Destructive Testing in Civil Engineering (NDT-CE)*, Berlin, Germany, pp.1074-1083, Sep. 2015.
- [15] H. M. Lee, H. S. Lee, "Prediction of Carbonation Progress of Concrete Using Deep Learning", *Proceedings of the Korea Concrete Institute*, Jeju, Korea, pp.171-172, May 2017.
- [16] D. H. Jung, H. S. Lee, "A Fundamental Study on the Prediction of Carbonation Progress Using Deep Learning Algorithm Considering Mixing Factors", *Proceedings of the Korea Institute of Building Construction*, Yeosu, Korea, pp.30-31, May 2019.
- [17] D. H. Jung, H. S. Lee, "A Fundamental Study on the Effect of Activation Function in Predicting Carbonation Progress Using Deep Learning Algorithm", *Proceedings of the Korea Institute of Building Construction*, Chungju, Korea, pp.60-61, Nov. 2019.
- [18] N. D. Lewis, *Deep Learning: Made Easy with R*, p.283, Acorn Publishing Co., 2017, pp.34-79.
- [19] B. Lantz, *Machine Learning with R: 2nd ed.*, p.566, Acorn Publishing Co., 2017, pp.122-310.
- [20] G. Hinton, N. Srivastava, A. Krizhevsky, I. Sutskever, R. R. Salakhutdinov, Improving neural networks by preventing co-adaptation of feature detectors [Internet]. Department of Computer Science, University of Toronto, c2012 [cited 2020 Oct. 5], available From: <http://arxiv.org/abs/1207.0580> (accessed Dec. 16, 2020)
- [21] A. Nazari, F. P. Torgal, "Predicting compressive strength of different geopolymers by artificial neural networks", *Ceramics International*, Vol.39, No.3, pp.2247-2257, Apr. 2019.  
DOI: <http://dx.doi.org/10.1016/j.ceramint.2012.08.070>
- [22] KCI, Standard Specification for Concrete; Maintenance Description, p.189, Korea Concrete Institute, 2005, pp.77-106.
- [23] AIJ, Japanese Architectural Standard Specification JASS 5: Reinforced concrete construction, p.754, Architectural Institute of Japan, 1997.

윤 병 돈(Byong-Don Youn)

[정회원]



- 1996년 8월 : 인하대학교 대학원 토목공학과 (공학석사)
- 2021년 3월 : 일본 규슈대학교 대학원 건설시스템공학과 (박사수료)
- 2012년 1월 ~ 현재 : ㈜플랜을이 엔씨 연구개발부문 전무이사

<관심분야>

Structural Health Monitoring, Concrete Durability, Artificial Intelligence