

인공 신경망 알고리즘을 활용한 플라이애시 콘크리트의 염해 내구성능 예측

권성준¹, 윤용식^{2*}

The Prediction of Durability Performance for Chloride Ingress in Fly Ash Concrete by Artificial Neural Network Algorithm

Seung-Jun Kwon¹, Yong-Sik Yoon^{2*}

Abstract: In this study, RCPTs (Rapid Chloride Penetration Test) were performed for fly ash concrete with curing age of 4 ~ 6 years. The concrete mixtures were prepared with 3 levels of water to binder ratio (0.37, 0.42, and 0.47) and 2 levels of substitution ratio of fly ash (0 and 30%), and the improved passed charges of chloride ion behavior were quantitatively analyzed. Additionally, the results were trained through the univariate time series models consisted of GRU (Gated Recurrent Unit) algorithm and those from the models were evaluated. As the result of the RCPT, fly ash concrete showed the reduced passed charges with period and an more improved resistance to chloride penetration than OPC concrete. At the final evaluation period (6 years), fly ash concrete showed 'Very low' grade in all W/B (water to binder) ratio, however OPC concrete showed 'Moderate' grade in the condition with the highest W/B ratio (0.47). The adopted algorithm of GRU for this study can analyze time series data and has the advantage like operation efficiency. The deep learning model with 4 hidden layers was designed, and it provided a reasonable prediction results of passed charge. The deep learning model from this study has a limitation of single consideration of a univariate time series characteristic, but it is in the developing process of providing various characteristics of concrete like strength and diffusion coefficient through additional studies.

Keywords: Passed charge, Chloride ingress, Fly ash, GRU, Deep learning model

1. 서 론

콘크리트는 높은 내구성능과 함께 경제성 및 공학적 성능을 확보한 범용적인 건설재료다. 하지만 가혹한 노출환경에 장기간 노출되는 경우 내구성능 저하로 인한 다양한 문제가 발생하게 된다. 콘크리트의 대표적인 열화 현상으로는 염해, 탄산화, 동결융해, 알칼리 골재 반응, 황산염에 의한 침식 등이 있다(Metha and Monteiro, 1993).

그 중 염해(Chloride Ingress)는 RC(Reinforced Concrete) 구조 내부로 염소 이온(Cl⁻)이 확산하여 발생하는 열화 현상으로서 내부 강재의 부식을 유발하며 최종적으로 구조적 문제를 야기한다(Broomfield, 1997; Oh et al., 2016). 특히, 우리나라의 경우 삼면이 바다에 접하고 있어 해안 및 연안해역 등에 콘크리트 구조물의 시공이 활발히 이루어지고 있기 때문에 염해에 더욱 취약한 지리적 조건을 갖고 있다(Moon et al., 2002;

Kirpatrick et al., 2002). 또한 해수 중의 염소 이온은 여러 할로젠 이온 중 전파속도가 가장 빠르고 보강재의 국소 부식(Pitting-corrosion)을 야기하여 RC 구조의 염해 내구성능 저하에 치명적이다(Lee and Zielske, 2014).

염해로 인한 콘크리트 구조의 내구성 저하를 제어하고자 다양한 연구가 수행되어왔으며, 그 중에서도 플라이애시(Fly Ash) 및 고로슬래그 미분말(Ground Granulated Blast Furnace Slag)과 같은 혼화재를 사용하는 방법이 효과적으로 알려져 있다(Nath and Sarker, 2011; Jau and Tsay, 1998; Thomas and Bamforth, 1999). 대표적인 콘크리트용 혼화재료인 플라이애시는 화력 발전소에서 석탄을 연소시킬 때 발생하는 특정 입도 범위(1 ~ 100 μm)의 미분말이다(KS L 5405, 2016). 플라이애시를 콘크리트에 포틀랜드 시멘트의 대체자원으로서 사용하는 경우, 포졸란 반응에 의해 장기 강도 및 내구성능 개선을 기대할 수 있으며 특히 염해 내구성능이 크게 개선되는 것으로 알려져 있다(Nath and Sarker, 2011). 또한 굳지 않은 상태에서는 구형의 입자에 의한 불 배어링 효과로 인해 워커빌리티의 증가 및 블리딩의 감소와 같은 공학적인 장점이 증가한다(Bilodeau et al., 1998).

적절한 시기에 염해에 대한 보수 작업이 수행되는 경우, 대량 콘크리트 구조물의 사용년한을 연장할 수 있을 뿐만 아니

¹정회원, 한남대학교 토목환경공학과 교수

²정회원, 한남대학교 토목환경공학과 연구교수

*Corresponding author: humbleyys@gmail.com

Department of Civil and Environmental Engineering, Hannam University, Daejeon, 34430, Korea

•본 논문에 대한 토의를 2022년 11월 30일까지 학회로 보내주시면 2022년 12월호에 토론결과를 게재하겠습니다.

라 구조물의 유지관리비용을 효율적으로 제어할 수 있다 (Borah et al., 2020; Yoon et al., 2020). 따라서 콘크리트의 염화물 확산 거동을 예측함으로써 적절한 보수 시점을 예측하고자 다양한 문헌에서 회귀분석 및 인공 신경망(Artificial Neural Network)을 활용한 예측 모델이 제안되어왔다(Thomas and Bentz, 2002; KCI, 2021; ACI, 2017; Yeh, 1998; Kim et al., 2002).

딥-러닝 알고리즘은 높은 수준의 추상적 개념에서 복잡한 특징을 추출하고 이를 자동화 하는 장점을 갖고 있으며 메인 알고리즘에 확보된 데이터를 학습시킴으로써 데이터의 분류 및 예측에 뛰어난 성능을 기대할 수 있다(Najafabadi et al., 2015). 딥-러닝 알고리즘을 활용한 연구가 최근 다양한 분야에서 시도되고 있으며, 콘크리트 분야에서는 강도 예측에 관한 연구가 활발히 이루어지고 있다(Chithra, 2016; Kim et al., 2002; Lee, 2003). 딥-러닝 알고리즘에서는 변수를 자체적으로 식별하여 조정함으로써 기존 모델들의 한계점을 보완할 수 있다(Lee, 2003). 이러한 딥-러닝 알고리즘을 기반으로 콘크리트의 강도 및 내구성능 예측에 관한 연구들이 수행되어 왔는데, 대부분 기존 재령일의 성능을 예측하므로 재령일의 증가에 따른 성능 변화 거동을 딥-러닝 알고리즘을 통해 분석할 수 있다면 시간의존적으로 변화하는 콘크리트의 특성을 더욱 효과적으로 분석할 수 있다(Lee, 2003, Jeong, 2020).

본 연구에서는 재령 4년 ~ 6년을 고려하여 평가된 OPC 및 플라이애시 콘크리트의 시간의존적 통과 전하량 및 압축강도 거동을 정량적으로 분석하였다. 재령 28일 ~ 3년까지의 시험 결과는 동일 배합을 다룬 선행 연구의 결과를 인용하였으며 재령의 증가, 배합 특성을 고려하여 분석하였다(Yoon and Kwon, 2020). 또한 확보된 각 배합의 통과 전하량을 학습 데이터로 활용하여 GRU(Gated Recurrent Unit)를 메인 알고리즘으로 구성된 딥-러닝 모델을 통해 통과 전하량 예측 모델을 제안하였다.

2. 플라이애시 콘크리트의 염해 저항성능 평가 방법

2.1 플라이애시 콘크리트 배합 및 사용재료

본 연구에서는 2수준의 플라이애시 치환률(0%, 30%)과 3수준의 물-결합제 비(0.37, 0.42, 0.47)를 적용한 콘크리트 배합을 사용하였다. 동일 배합을 다룬 선행 연구의 이전 재령일의 결과 값을 인용하였으며 배합 사항 및 사용 재료의 특성은 선행 연구와 동일하다. 본 연구에서 사용한 콘크리트 배합을 Table 1에 나타내었으며, Table 2 및 Table 3에 본 배합에 사용한 골재 및 감수제의 특성을 나타내었다(Yoon and Kwon, 2020).

Table 1 Mix proportions for OPC and FA concrete(Yoon and Kwon, 2020)

	W/B	Unit weight(kg/m ³)					S.P (%)
		W	C	FA	Fine Agg.	Coarse Agg.	
OPC	0.37	168	454	0	767	952	1.10
	0.42	168	400	0	787	976	1.00
	0.47	168	357	0	838	960	0.95
FA 30	0.37	168	318	136	745	952	1.40
	0.42	168	280	120	768	953	1.20
	0.47	168	250	107	820	939	1.00

W/B : Water to Binder ratio, W : Water, C : Cement, FA : Fly Ash, S.P : Super Plasticizer

Table 2 Physical properties of fine and coarse aggregate (Yoon and Kwon, 2020)

Types	Items	G _{max} (mm)	Specific gravity (g/cm ³)	Absorption (%)	F.M.
Fine aggregate		-	2.58	1.01	2.90
Coarse aggregate		25	2.64	0.82	6.87

F.M. : Fineness Modulus

Table 3 Properties of super-plasticizer(Yoon and Kwon, 2020)

Types	Items	Type	pH	Main component	Solid	Density
2000R		Liquid	6.7	Polycarbonic Acid	25 %	1.08

2.2 통과 전하량 평가 방법

본 연구에서는 ASTM C 1202에서 제안하는 시험 방법을 통해 OPC 및 플라이애시 콘크리트 배합의 염해 저항성능을 평가하였다. 이 시험 방법은 본질적으로 콘크리트 시편의 염화물 이온 침투 저항성을 평가하는 시험방법으로 알려져 있으며, 결과 값인 통과 전하량을 통해 축진 염화물 확산계수를 경험식으로 도출할 수 있다(Berke and Hicks, 1994).

측면에 에폭시가 도포된 5 cm 두께의 디스크 시편을 대상으로 Cell I(음극)에는 3%의 염화나트륨(NaCl) 수용액을, Cell II(양극)에는 0.3 M 수산화나트륨(NaOH) 수용액을 적용하여 6 시간동안 60 V의 전압을 인가하였다. 통과 전하량 평가 전경을 Fig. 1에 나타내었다. 전압을 인가하는 동안 30분 간격으로 통과 전류 값을 측정하여 아래의 식 (1)을 통해 통과 전하량을 산출하였다. 각 평가일 마다 3회 씩 통과 전하량을 평가한 후 이를 평균으로 계산하여 최종 결과 값으로 사용하였다. ASTM C 1202에서는 Table 4와 같은 기준을 통해 통과

Table 4 Evaluation standard of passed charge of chloride ions (ASTM C 1202, 2005)

Total passed charge (Coulomb)	Chloride ions permeability
> 4,000	High
2,000 ~ 4,000	Moderate
1,000 ~ 2,000	Low
100 ~ 1,000	Very low
< 100	Negligible




Fig. 1 The photo for ASTM C 1202

전하량으로 콘크리트의 염화물 확산 저항성을 평가한다 (ASTM C 1202, 2005).

$$Q = 900(I_0 + 2I_{30} + 2I_{60} + \dots + 2I_{330} + I_{360}) \quad (1)$$

여기서 Q 는 통과 전하량(Coulomb)을 나타내고 있으며, I_x 는 x 분에서의 전류 값(A)을 나타낸다.

2.3 압축강도 평가 방법

재령 4년 ~ 6년의 OPC 및 플라이애시 콘크리트 시편을 대상으로 KS F 2405에 준하여 압축강도를 평가하였다(KS F

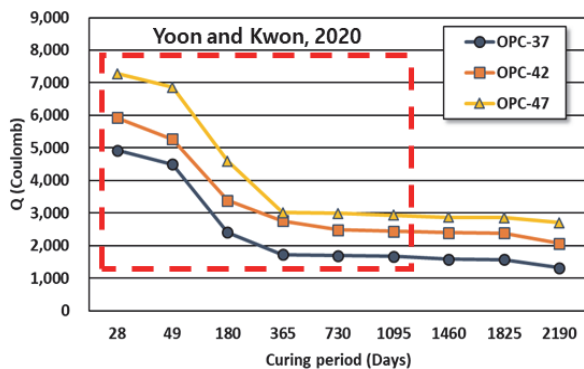
2405, 2015). 선행 연구에서 평가한 재령 3년까지의 압축강도 거동을 바탕으로 최대 2,190일(6년)까지의 재령일을 고려하여 재령에 따라 증가하는 압축강도 거동을 분석하였다(Yoon and Kwon, 2020). 2.2절의 통과 전하량과 마찬가지로 각 재령일에 배합별로 3회 씩 압축강도를 평가한 후 이를 평균으로 하여 결과 분석에 사용하였다.

3. 플라이애시 콘크리트의 통과 전하량 및 압축강도 평가 결과

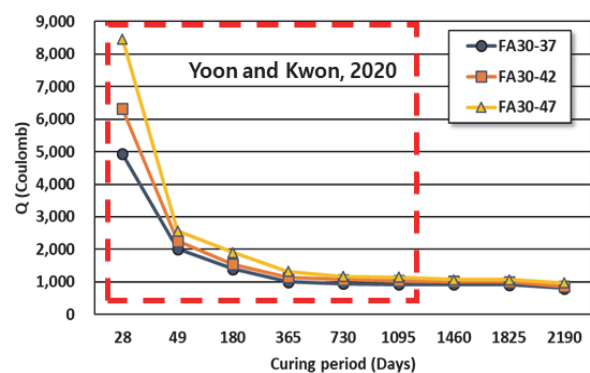
3.1 플라이애시 콘크리트의 시간의존적 통과전하량 평가 결과

본 절에서는 ASTM C 1202에 준하여 재령 4년 ~ 6년에서의 OPC 및 플라이애시 콘크리트의 통과 전하량을 평가한 결과를 정량적으로 분석하였다. 재령 28일 ~ 3년의 결과는 동일 배합을 다룬 선행 연구에서 인용하였다(Yoon and Kwon, 2020). Fig. 2에 각 배합의 재령에 따른 통과전하량 변화 거동을 나타내었다.

직전 측정일인 재령 1,095일을 기준으로 최종 측정일인 재령 2,190일에서의 통과 전하량 감소율을 평가하면 OPC 콘크리트의 경우 7.92% ~ 20.70%, 플라이애시 콘크리트의 경우 13.62% ~ 16.45%로 평가되었다. 플라이애시 콘크리트는 OPC 콘크리트 대비 낮은 통과 전하량 값을 나타낼 뿐만 아니라 재령이 증가함에 따라 큰 폭의 통과 전하량 감소를 나타내었다. 재령 3년 이후로 OPC 콘크리트는 물-결합재 비가 높은 경우(W/B: 0.47)에서 ‘Moderate’ 등급을, 나머지 경우에서 ‘Low’ 등급을 나타내었으며 플라이애시 콘크리트는 최종 재령일인 2,190일에서 모두 ‘Very low’ 등급을 나타내었다. 또한 플라이애시 콘크리트에서는 재령이 증가함에 따라 물-결합재 비가 통과 전하량에 미치는 영향이 크게 감소하였으며,



(a) OPC concrete



(b) FA 30 concrete

Fig. 2 The results of passed charge in FA and OPC concrete

OPC 콘크리트와 플라이애시 콘크리트의 물-결합재 비에 의한 통과 전하량의 증가율을 Fig. 3에 나타내었다. Fig. 3에서는 각 평가 기간에서 물-결합재 비 0.37 대비 0.47에서의 통과 전하량 증가율을 분석하였다. 재령 28일을 제외하고 플라이애시 콘크리트에서 OPC 콘크리트 대비 낮은 물-결합재 비에 의한 변동성을 나타내었으며 플라이애시 콘크리트는 재령이 증가함에 따라 통과 전하량의 증가율이 감소하지만 OPC 콘크리트의 경우 뚜렷한 경향을 나타내지 않았다.

3.2 플라이애시 콘크리트의 시간의존적 압축강도 평가 결과

본 절에서는 KS F 2405에 준하여 재령 4년 ~ 6년에서의 OPC 및 플라이애시 콘크리트의 압축강도를 평가한 결과를 분석하였다. 3.1절과 마찬가지로 재령 28일 ~ 3년의 결과는 동일 배합을 다룬 선행 연구에서 인용하였다(Yoon and Kwon, 2020). Fig. 4에 각 배합의 재령에 따른 압축강도 증가 거동을 나타내었다.

선행 연구의 마지막 측정일인 재령 3년을 기준으로 재령 6년의 압축강도 증가율을 평가한 결과, OPC 콘크리트의 경우 103.9 ~ 106.7 %, 플라이애시 콘크리트의 경우 101.4 ~ 106.5 %가 평가되었다. 두 배합 간의 강도 증진률은 큰 차이가 없었

으나 모든 평가일에서 플라이애시 콘크리트가 더 높은 강도를 나타내었다. 재령 2,190일에서 플라이애시 콘크리트는 OPC 콘크리트 대비 110.2 ~ 123.1 %의 압축 강도를 나타내었다. 각 재령일에서 물-결합재 비가 감소함에 따른 압축강도의 증가율을 평가한 결과를 Fig. 5에 나타내었다. 압축강도의 경우 재령 730일 이후 두 배합 간의 물-결합재 비에 의한 강도 변동성의 차이가 매우 적게 나타났다. 플라이애시 콘크리트의 경우 초기 재령에서부터 물-결합재 비에 의한 강도 품질 확보에 OPC 콘크리트 대비 유리한 것으로 보인다.

4. 인공 신경망 알고리즘을 활용한 플라이애시 콘크리트의 통과전하량 거동 예측

4.1 플라이애시 콘크리트의 염화물 통과전하량 예측을 위한 딥-러닝 모델의 해석 조건

본 연구에서는 인공 신경망 알고리즘을 활용하여 본 연구에서 평가한 6수준의 배합을 대상으로 통과 전하량 예측 모델을 평가하였다. 본 연구에서 확보한 6개 배합의 재령 4년 ~ 6년을 고려하여 평가된 통과 전하량 결과와 선행 연구의 재령 28일 ~ 3년의 결과 값(Yoon and Kwon, 2020)을 학습 데이터




Fig. 3 The increasing rate of passed charge by W/B ratio




Fig. 5 The increasing rate of compressive strength by W/B ratio

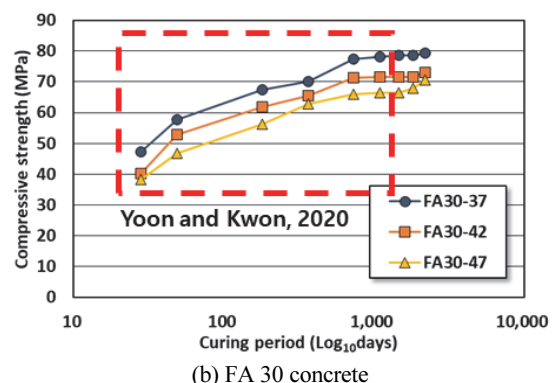
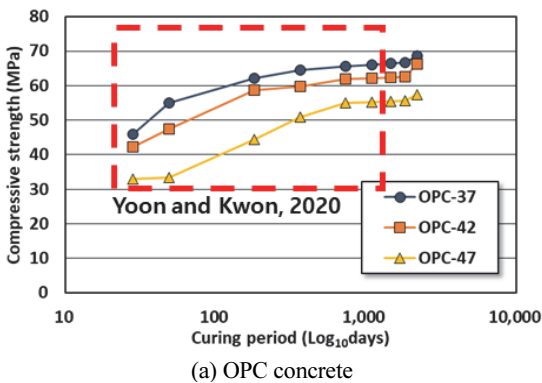


Fig. 4 The results of compressive strength in FA and OPC concrete

로 활용하여 단변량 시계열 분석을 수행하였으며 직전 3개의 데이터를 기반으로 그 다음 데이터를 예측하는 모델을 설계하였다. 본 연구에서는 각 배합 마다 총 9개의 평가 결과(재령 28일~6년)를 확보하였는데 이를 그대로 머신러닝의 입력 데이터로 활용하는 경우 데이터 량의 부족 문제로 인해 큰 오차가 발생하였다. 이러한 문제를 해결하기 위해 총 9개의 평가 일 사이에 선형 보간을 적용하여 1일 간격으로 데이터를 보충하였으며, 최종적으로 각 배합은 2,193개의 결과 데이터를 갖게 되었다. 본 연구에서 딥-러닝 모델을 구성하기 위해 활용한 학습 데이터를 Table 5에 나타내었으며, 배합 명 뒤의 숫자는 물-결합재 비를 의미한다.

평가 시 사용한 인공 신경망 알고리즘으로는 GRU(Gated Recurrent Unit)를 선정하였으며 GRU는 시계열 데이터를 분석할 수 있고 연산이 빠른 장점이 있다(Jeon et al., 2021). 본 연구의 딥-러닝 모델은 총 4개의 은닉층으로 구성되어있으며 train data의 과적합을 방지하고자 각 은닉층마다 10%의 드롭아웃을 적용하였다. test data 및 validation data의 분배는 재령 5년 및 6년이 각각 test 및 validation 데이터에 포함될 수 있도록 각각 전체 데이터의 11.20%(각 245개의 데이터)의 비율로 설정하였으며, 나머지 데이터는 train data로 활용하였다. 딥-러닝 모델 구동 시 test data를 이용하여 모델을 평가하게 되면 test data 위주의 모델을 구성하게 되어 해당 모델이 적절한 일

Table 5 The train data of passed charge in OPC and FA concrete for deep learning model

	Q(Coulomb)				
	Train data				
	28 days	49 days	180 days	365 days	730 days
OPC-37	4,922.6	4,494.6	2,408.4	1,728.4	1,692.0
OPC-42	5,924.2	5,266.8	3,380.4	2,754.0	2,484.0
OPC-47	7,283.4	6,863.4	4,597.2	3,011.4	2,986.2
FA 30-37	4,936.2	2,012.4	1,401.0	1,007.6	953.0
FA 30-42	6,320.6	2,262.6	1,537.0	1,149.2	1,064
FA 30-47	8,458.3	2,566.8	1,904.4	1,324.6	1,163
	Train data	Test data	Validation data		
	1,095 days	1,460 days	1,825 days	2,190 days	
OPC-37	1,663.7	1,585.6	1,568.9	1,319.2	
OPC-42	2,435.3	2,392.4	2,385.1	2,062.8	
OPC-47	2,935.3	2,863.2	2,857.4	2,702.9	
FA 30-37	928.3	920.3	913.6	801.9	
FA 30-42	1,034.2	1,009.6	1,003.6	864.0	
FA 30-47	1,141.6	1,071.7	1,067.2	966.6	

반화 성능을 갖출 수 없게 된다. 따라서 본 연구에서는 validation data를 고려하여 모델을 구성 후 test data는 마지막에 1회만 사용하여 개발된 모델의 성능을 평가하였다. 딥-러닝 모델 구성 시 손실함수로서 root-mean-square error, mean absolute error, mean absolute percent error 등과 같은 다양한 함수가 사용되고 있다. 본 연구에서는 딥-러닝 모델 구성 시 다양한 손실함수와 이에 따른 매개변수 조정을 수행하여 최적 손실함수로서 평균제곱오차(MSE: Mean Squared Error)를 선정하였다. 이를 통해 딥-러닝 모델의 epoch의 진행에 따른 손실 거동을 평가하였으며 MSE 평가 식을 아래 식 (2)에 나타내었다. 본 연구에서 수행한 딥-러닝 해석 조건을 아래 Table 6에, 딥러닝 모델의 개요를 Fig. 6에 나타내었다.

Table 6 The analysis condition of deep learning model for prediction of passed charge

Main Algorithm	Activation Function	Nodes	Cost Function
GRU	Hyperbolic tangent function	64	MSE (Mean Squared Error)
Learning rate	Weight Decay	Drop out	The number of epochs
1.5 %	0.001	10 %	25
Optimizer			
SGD (Stochastic Gradient Descent)			

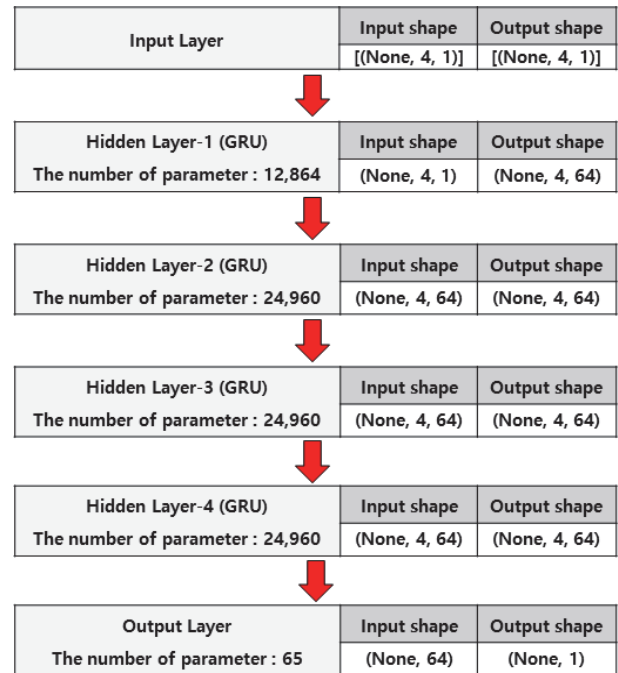


Fig. 6 The overview of deep learning model for prediction of passed charge

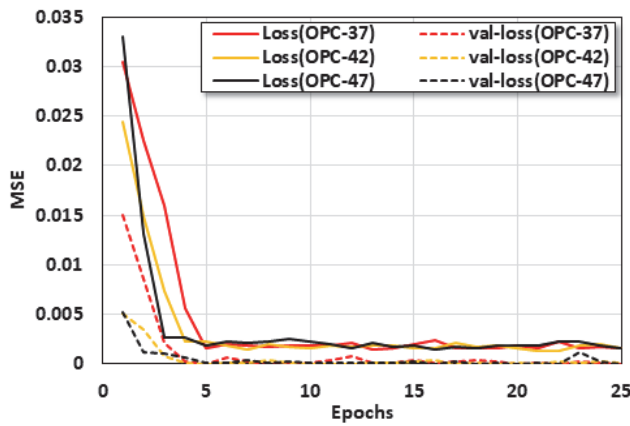
$$MSE = \frac{1}{n} \sum_i^n (y_i - \tilde{y}_i)^2 \quad (2)$$

여기서 n 데이터 세트 내 데이터의 수를, y_i 는 예측된 통과 전하량을, \tilde{y}_i 는 측정된 통과 전하량 값을 나타낸다.

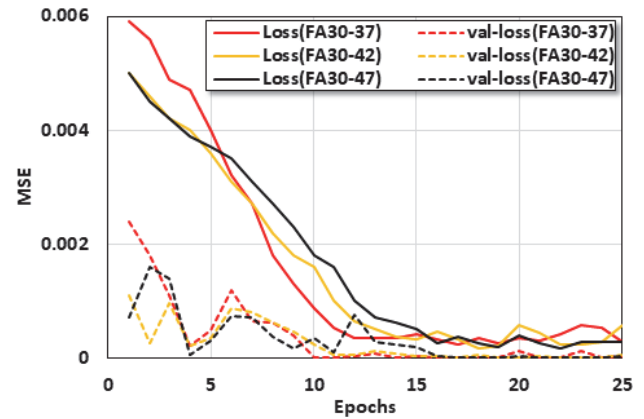
4.2 플라이애시 콘크리트의 통과전하량 예측을 위한 딥-러닝 모델의 해석 결과

본 절에서는 재령 28일 ~ 6년에 평가된 3수준의 물-결합재비를 고려한 OPC 및 플라이애시 콘크리트의 통과 전하량을 기반으로 분석한 딥-러닝 모델의 평가 결과를 다루었다. train data 및 validation data의 처리 과정에서 최대 25 epochs까지 매 epoch 마다 계산된 평균제곱오차(Mean Squared Error)를 Fig. 7에 나타내었다. 또한 딥-러닝 모델을 통해 예측한 각 배합의 재령 6년(Validation data), 6년(Test data)의 통과 전하량과 시험 값 간의 비교 결과를 Fig. 8에 나타내었다.

평균제곱오차 평가 결과 Fig. 7과 마찬가지로 epoch가 증가함에 따라 감소하는 경향이 나타났으며 epoch의 진행 중 일부 조건에서 손실이 다소 증가하는 경우가 나타났으나 이는 딥-러닝 모델의 구동 시 drop out 등에 의해 발생한 불확실성으로 사료되며 25회의 epoch 횟수는 본 연구의 데이터 분석에 충분한 것으로 사료된다. Fig. 8에 나타난바와 같이 본 연구의 딥-러닝 모델을 통해 OPC 및 플라이애시 콘크리트의 재령 5년 및 재령 6년의 통과 전하량을 예측한 결과는 실험을 통해 얻은 값과 매우 적은 차이를 나타내었다. 통과 전하량의 실험 값과 예측 값의 차이는 결합재의 종류나 물-결합재 비와 같은 배합 특성에 의한 경향을 나타내지 않았다. 각 배합의 시험 값과 예측 값의 간의 차이를 절댓값으로 평가한 후 측정값에 대한 비율로 나타내어 이를 오차로 고려하면 Fig. 9와 같다. OPC 콘크리트 배합의 경우 0.13% ~ 1.71%, 플라이애시 콘크리트 배합의 경우 0.20% ~ 7.64%의 오차를 나타내었다. 본 연구에서 제안한 염화물 거동 예측을 위한 딥-러닝 모델은 단일 배합



(a) OPC concrete



(b) FA 30 concrete

Fig. 7 The analysis result of MSE by deep learning model




Fig. 8 The comparison of measured HCP and predicted HCP by deep learning model

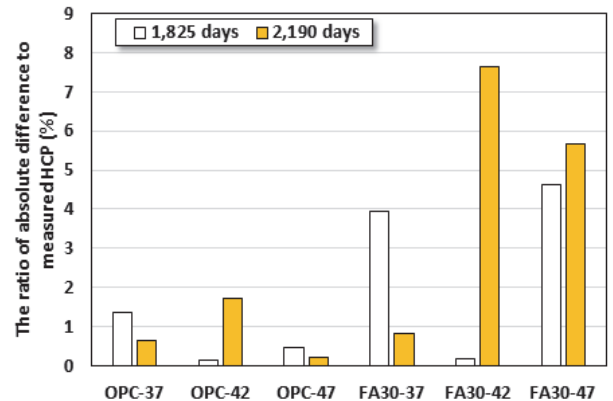


Fig. 9 The ratio of absolute difference between measured and predicted HCP to measured HCP

특성만을 고려할 수 있는 한계를 갖고 있으며 강도, 확산계수 등을 다변량으로 동시에 고려할 수 있는 모델을 추가 연구를 통해 개발 중에 있다. 또한 추가 장기 재령일에서의 통과 전하량 평가가 계획되어 있으며 이를 통해 콘크리트의 장기 거동 고려 시 더욱 신뢰할 수 있는 통과 전하량 예측 모델을 제안할 수 있을 것으로 사료된다.

5. 결 론

본 연구에서는 장기재령 OPC 및 플라이애시 콘크리트를 대상으로 ASTM C 1202의 실험 결과를 분석하였다. 재령일로는 4, 5, 6년을, 배합특성으로는 플라이애시 치환률 2수준(0%, 30%) 및 물-결합재 비 3수준(0.37, 0.42, 0.47)을 고려하였다. 또한 본 연구에서는 동일 배합을 다룬 선행 연구를 통해 추가 시험 데이터를 확보 후 이를 기반으로 GRU 알고리즘 기반 변량 시계열 분석을 통해 각 배합의 통과 전하량 예측 모델을 평가하였다. 본 연구의 결론은 다음과 같다.

- 1) ASTM C 1202에 준하여 각 배합의 통과 전하량을 평가한 결과, OPC 콘크리트의 경우 최종 평가일인 재령 6년에서 물 결합재 비 0.37인 경우 ‘Low’ 등급을 나머지 두 경우에서는 ‘Moderate’ 등급을 나타내었다. 플라이애시 콘크리트의 경우 모든 물-결합재 비 조건에서 ‘Very low’ 등급을 나타내었다. 재령 3년의 결과와 6년의 결과를 비교 평가하는 경우, 플라이애시 콘크리트는 OPC 콘크리트 대비 낮은 통과 전하량 값을 뿐만 아니라 재령의 증가에 따라 큰 폭의 통과 전하량 감소를 나타내었다. 또한 플라이애시 콘크리트는 OPC 콘크리트 대비 물-결합재 비에 의한 통과 전하량의 변동이 적게 나타났으며 이 변화율은 재령이 증가함에 따라 감소하는 거동을 나타내었다.
- 2) 본 연구에서는 수중 양생 기간 4년 ~ 6년을 고려하여 OPC 및 플라이애시 콘크리트의 압축강도 거동을 평가하였다. 선행 연구의 최종 평가일인 재령 3년을 기준으로 재령 6년에서의 압축강도 증진률을 평가한 결과, OPC 콘크리트의 경우 103.9 ~ 106.7%, 플라이애시 콘크리트의 경우 101.4 ~ 106.5%로 평가되어 결합재의 종류 간에 큰 차이가 발생하지 않았다. 하지만 플라이애시 콘크리트는 OPC 콘크리트 대비 높은 강도 값을 나타내었으며 재령 6년에서 플라이애시 콘크리트는 OPC 콘크리트 대비 최대 123.1%의 강도를 나타내었다.
- 3) 본 연구에서는 인공 신경망 알고리즘 중 시계열 분석이 가능한 GRU 알고리즘을 기반으로 딥-러닝 모델을 구성하여 각 배합의 통과 전하량 예측을 수행하였다. 평균제곱오차를 통해 모델을 평가한 결과, 예측된 통과 전하량

과 측정된 통과 전하량 간의 오차는 OPC 콘크리트 배합의 경우 0.13% ~ 1.71%, 플라이애시 콘크리트 배합의 경우 0.20% ~ 7.64%로 평가되어 매우 적은 오차를 나타내었다. 본 연구의 통과 전하량 예측 딥-러닝 모델은 단일 배합만을 고려할 수 있는 한계점을 갖고 있으며 추가 연구를 통해 콘크리트의 다양한 특성을 동시에 고려할 수 있는 다 변량 모델의 개발이 수행 중에 있다.

감사의 글

이 논문은 2021년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(No. NRF-2021R1A6A3A01086622).

References

1. Metha, P. K., and Monteiro, P. M. (1993), Concrete: structure, properties, and materials, 2nd edition, prentice Hall, New-Jersey, 113-171.
2. Broomfield, J. P. (1997), Corrosion of Steel in Concrete: Understanding, Investigation and Repair, E&FN, London. 1-15.
3. Oh, K. S., Park, K. T., and Kwon, S. J. (2016), Evaluation of Anti-Corrosion Performance of FRP Hybrid Bar with Notch in GGBFS Concrete, *Journal of the Korea Institute for Structural Maintenance and Inspection*, 20(4), 51-58.
4. Moon, H. Y., Kim, H. S., and Lee, S. T. (2002), Examination on the Deterioration of Concrete due to Seawater Attack, *Journal of the Korean Society of Civil Engineers*, 22(1A), 171-179.
5. Kirkpatrick, T. J., Weyers, R. E., Anderson-Cook, C. M., and Sprinkel, M. M. (2002), Probabilistic Model for the Chloride-induced Corrosion Service Life of Bridge Decks, *Cement and Concrete Research*, 32(12), 1943-1960.
6. Lee, S. K., and Zielske, J. (2014), An FHWA Special Study: Post-Tensioning Tendon Grout Chloride Thresholds(FHWA-HRT-14-039), Federal Highway Administration, McLean, 7-20.
7. Nath, P., and Sarker, P. (2011), Effect of Fly Ash on the Durability Properties of High Strength Concrete, *Procedia Engineering*, 14, 1149-1156.
8. Jau, W. C., and Tsay, D. S. (1998), A Study of The Basic Engineering Properties of Slag Cement Concrete and Its Resistance to Seawater Corrosion, *Cement and Concrete Research*, 28(10), 1363-1371.
9. Thamoas, M. D. A., and Bamforth, P. B. (1999), Modelling Chloride Diffusion in Concrete Effect of Fly Ash and Slag, *Cement and Concrete Research*, 29(4), 487-495.
10. KS L 5405. (2016), Fly Ash, Korea Standard Service Network, Republic of Korea, 1-8.
11. Bilodeau, A., Malhotra, V. M., and Golden, D. M. (1998), Mechanical properties and durability of structural lightweight concrete incorporating high-volumes of fly ash, *ACI International*, 178, 449-474.

12. Borah, M. M., Dey, A., and Sil, A. (2020), Service life assessment of chloride affected bridge located in coastal region of India considering variation in the inherent structural parameters, *Structures*, 23, 191-203.
13. Yoon, Y. S., Kim, T. H., and Kwon, S. J. (2020), Evaluation of Chloride Diffusion Behavior and Analysis of Probabilistic Service Life in Long Term Aged GGBFS Concrete, *Journal of the Korea Institute for Structural Maintenance and Inspection*, 24(3), 47-56.
14. Thomas, M. D. A., and Bentz, E. C. (2002), Computer Program for Predicting the Service Life and Life-cycle Costs of Reinforced Concrete Exposed to Chlorides(Life365 Manual), SFA, Lovettsville.
15. KCI. (2021), KDS 14 20 40-Durability Design Standard for Concrete Structure, Korea Concrete Institute, Seoul, 652-653.
16. ACI. (2017), ACI 365.1R-17-Report on Service Life Prediction, ACI Committee 365, American Concrete Institute, Farmington Hills, 42-45.
17. Yeh, I. C. (1998), Modeling of strength of high-performance concrete using artificial neural networks, *Cement and Concrete research*, 28(12), 1797-1808.
18. Kim, I. S., Lee, J. H., Yang, D. S., and Park, S. K. (2002), Prediction on Mix Proportion Factor and Strength of Concrete Using Neural Network, *Journal of the Korean Concrete Institute*, 14(4), 457-466.
19. Najafabadi, M. M., Villanustre, F., Khoshgoftaar, T. M., Seliya, N., Wald, R., and Muharemagic, E. (2015), Deep learning applications and challenges in big data analytics. *Journal of big data*, 2(1), 1-21.
20. Chithra, S., Kumar, S. S., Chinnaraju, K., and Ashmita, F. A. (2016), A comparative study on the compressive strength prediction models for High Performance Concrete containing nano silica and copper slag using regression analysis and Artificial Neural Networks, *Construction and Building Materials*, 114, 528-535.
21. Lee, S. C. (2003), Prediction of concrete strength using artificial neural networks, *Engineering structures*, 25(7), 849-857.
22. Jeong, D. H. (2020), A study on prediction of concrete carbonation using deep learning, Master's thesis, Ansan: Hanyang University, Department of Architectural Engineering.
23. Yoon, Y. S., and Kwon, S. J. (2020), Evaluation of Chloride Behavior and Service Life in Long-Term Aged FA Concrete through Probabilistic Analysis, *Journal of the Korean Recycled Construction Resources Institute*, 8(3), 276-285.
24. Berke N. S., and Hicks, M. C. (1994), Predicting Chloride Profiles in Concrete, *CORROSION*, 50(3), 234-239.
25. ASTM C 1202. (2005), Standard Test Method for Electrical Indication of Concrete's Ability to Resist Chloride Ion Penetration, American Society for Testing and Materials.
26. KS F 2405. (2015), Standard Test Method for Compressive Strength of Concrete, KSSN, 1-3.
27. Jeon, G. Y., Park, J. H., Jung, J. W. and Yoon, H. C. (2021), Structural Response Estimation Using Gated Recurrent Unit, *Journal of the Korean Society of Hazard Mitigation*, 21(3), 171-179.

Received : 09/14/2022
 Revised : 10/16/2022
 Accepted : 10/20/2022

요 지 : 본 연구에서는 장기재령(4~6년)으로 양생된 플라이애시 콘크리트를 대상으로 축진 염화물 이온 통과 시험을 수행하였다. 콘크리트 배합은 3수준의 물-결합재 비(0.37, 0.42, 0.47)와 2수준의 플라이애시 치환율(0, 30 %)을 가지고 있었으며, 시간 의존적으로 개선되는 통과 전하량을 정량적으로 분석하였다. 또한 실험결과를 GRU 알고리즘을 고려한 단변량 시계열 모델을 적용하여 학습하였으며, 그 예측값을 평가하였다. 통과전하량 실험 결과, 플라이애시 콘크리트는 물-결합재 비에 의한 통과 전하량의 변화가 재령이 증가함에 따라 점차 감소하였으며 OPC 콘크리트에 비하여 우수한 염해저항성을 나타내었다. 최종 평가일인 6년에서 플라이애시 콘크리트는 모든 물 결합재 비 조건에서 'Very low' 등급에 해당되는 통과 전하량이 평가되었지만, OPC 콘크리트의 경우 가장 높은 물-결합재 비를 갖는 조건에서 'Moderate' 등급을 나타내었다. 메인 알고리즘으로서 사용한 GRU 알고리즘은 시계열 데이터를 분석할 수 있고 연산 속도가 빠른 장점을 갖고 있다. 4개의 은닉층을 갖는 딥-러닝 모델이 고려되었으며 결과값은 실험값을 합리적으로 예측하고 있었다. 본 연구의 딥-러닝 모델은 단변량 시계열 특성만을 고려할 수 있는 한계점이 존재하지만 추가 연구를 통해 콘크리트의 강도 및 확산계수와 같은 다양한 특성을 고려할 수 있는 모델이 개발 중에 있다.

핵심용어 : 통과 전하량, 염해, 플라이애시, 게이트 순환 유닛, 딥-러닝 모델
