

압축강도 기반의 콘크리트 품질관리를 위한 웹 전산모델 개발

Numerical Web Model for Quality Management of Concrete based on Compressive Strength

이 군 재¹김 학 영^{2*}이 혜 진³황 승 현³양 근 혁⁴Lee, Goon-Jae¹Kim, Hak-Young^{2*}Lee, Hye-Jin³Hwang, Seung-Hyeon³Yang, Keun-Hyeok⁴*Assistant Professor, Department of Civil Engineering, SangMyung University, Cheonan, 31066, Korea ¹**Research professor, Department of Architectural Engineering, Kyonggi University, Suwon, 16227, Korea ²**Doctor's Course, Graduate School, Kyonggi University, Suwon, 16227, Korea ³**Professor, Department of Architectural Engineering, Kyonggi University, Suwon, 16227, Korea ⁴*

Abstract

Concrete quality is mainly managed through the reliable prediction and control of compressive strength. Although related industries have established a relevant datasets based on the mixture proportions and compressive strength gain, whereas they have not been shared due to various reasons including technology leakage. Consequently, the costs and efforts for quality control have been wasted excessively. This study aimed to develop a web-based numerical model, which would present diverse optimal values including concrete strength prediction to the user, and to establish a sustainable database (DB) collection system by inducing the data entered by the user to be collected for the DB. The system handles the overall technology related to the concrete. Particularly, it predicts compressive strength at a mean accuracy of 89.2% by applying the artificial neural network method, modeled based on extensive DBs.

Keywords : structured query language, artificial neural network, compressive strength of concrete, database

1. 서 론

1.1 연구의 배경

국내 건설산업에서는 생산 및 품질관리 정보의 필요성과 그 활용에 대한 중요성은 인식되고 있으나, 대부분 공개되지 않거나 제대로 활용되지 못하고 있는 실정이다[1]. 콘크리트의 유동성을 비롯해 압축강도 및 설계 배합표 등은 관련 업체별로 상당한 수의 데이터베이스(DB)가 이미 구축되어 있다. 하지만 기술유출 등의 이유로 공유되지

못해 결과적으로 건설 품질관리를 위한 비용과 노력은 과도하게 낭비되고 있는 셈이다. 소규모의 레미콘 업체 및 현장에서는 콘크리트 배합설계 자체에 어려움을 겪고 있어 배합강도나 W/C 설정에 안전율을 과도 혹은 과소하게 설정할 경우 비용소모 및 품질저하를 유발할 수 있다[2].

또한 혼화재(SCM)나 경량골재(LWA)와 같이 상대적으로 국내 레미콘 적용빈도가 낮은 재료의 경우 이를 혼입한 콘크리트의 현장실험 결과는 상대적으로 매우 부족하다. 이에 따라 배합의 신뢰도 재고를 위해서는 다수의 실험결과가 공유될 필요가 있으나 이를 위한 인프라도 현재로서는 현저히 미흡한 실정이다[3,4].

본 연구의 목적은 콘크리트 품질관리 전반을 위한 웹 기반 전산모델을 제시하여 사용자에게 콘크리트 배합설계 및 압축강도 예측을 위한 직관적 결과를 제공하는데 있다. 이를 위해 다수의 DB를 활용한 인공지능망 기법 및 예측

Received : April 19, 2021

Revision received : May 10, 2021

Accepted : May 17, 2021

* Corresponding author : Kim, Hak-Young

[Tel: 82-10-8873-6694, E-mail: concrete@kgu.ac.kr]

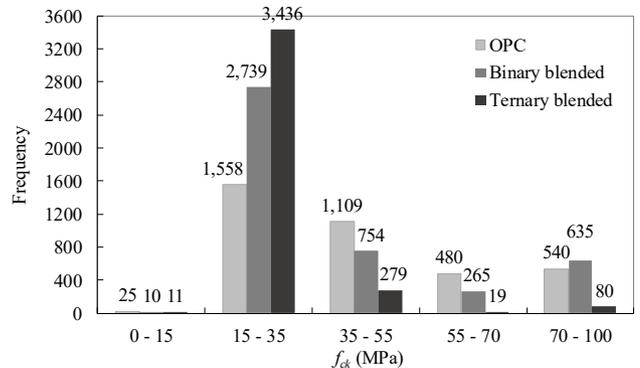
©2021 The Korea Institute of Building Construction, All rights reserved.

모델식에 기반해 사용자가 입력한 목표성능을 충족할 수 있는 콘크리트 최적 배합설계를 도출하거나, 반대로 사용 재료 특성과 시방 배합표를 입력할 시 재령별 압축강도 결과를 출력한다. 더불어 사용자가 입력한 재료 및 배합 인자는 구축된 Structured Query Language (SQL) 서버를 통해 자동 수집되며, 인공지능망의 학습량은 증가된다. 이는 콘크리트 배합과 관련해 지속적인 DB를 축적함으로써 출력 값의 정확도를 증가시키는 구조를 나타낸다. 연구에서 제시하는 전산모델 프로그램은 콘크리트 구성재료의 특성을 비롯해 주어진 배합인자에 따른 콘크리트의 성능발현, 전과정 환경영향평가 등 콘크리트와 관련된 대부분 정보를 포함하였다. 본 논문에서는 이 중 프로그램의 기본 구조와 인공지능망에 기반한 압축강도 예측 프로세스 그리고 SQL 서버 구축방안 등을 제시하였다.

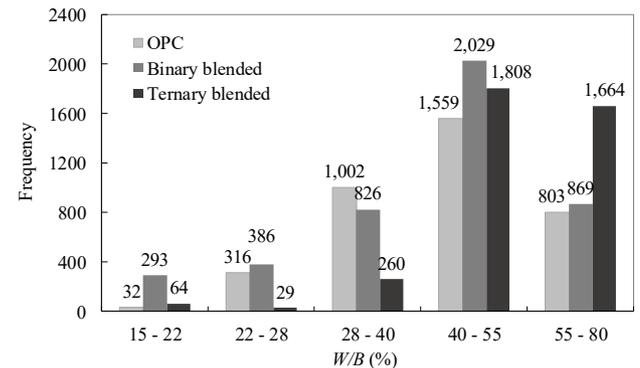
1.2 콘크리트 배합 데이터베이스 구축 현황

이 연구에서는 국내·외에서 발표된 논문 및 자체 실험 결과를 토대로 총 11,941개의 콘크리트 배합을 수집, 분석에 활용하였다(Figure 1). 수집대상 항목은 결합재의 종류 및 골재의 물리·화학적 특성을 비롯해 콘크리트의 배합설계 인자 그리고 다양한 성능결과 등이다. 특히 콘크리트의 강도와 CO₂ 배출량에 크게 영향을 미치는 결합재의 종류 및 SCM 치환율을 주된 인자로 구분하였다. 이에 OPC 단독 사용 배합과 2성분계 배합 (OPC+FA, OPC+GGBS, OPC+SF) 그리고 3성분계 배합 (OPC+FA+GGBS, OPC+GGBS+SF, OPC+FA+ SF)¹⁾을 각각 31.1%(3712개), 36.9%(4403개) 및 32.0%(3826개) 비율로 구성하였다. DB에 수집된 각 배합의 설계인자 및 결과 변수에 따른 빈도수는 Figure 1과 같다. 자료 수집의 상당비율이 국내 레미콘 배합을 대상으로 하고 있어, 재령 28일을 기준으로 하는 콘크리트 압축강도(f_{ck})는 15-35MPa 영역이 가장 빈도수가 높았으며 W/B는 40-55% 구간, 단위 결합재량은 280-480kg/m³ 구간이 가장 높은 빈도수를 나타냈다. 특히 SCM 치환에 따른 결합재의 종류는 FA를 치환한 배합이 가장 빈도수가 높았으며 이 중 2성분계 배합은 치환율 20% 이내의 범위, 3성분계 배합은 치환율 20-50% 이내가 가장 높은 빈도수를 나타냈다.

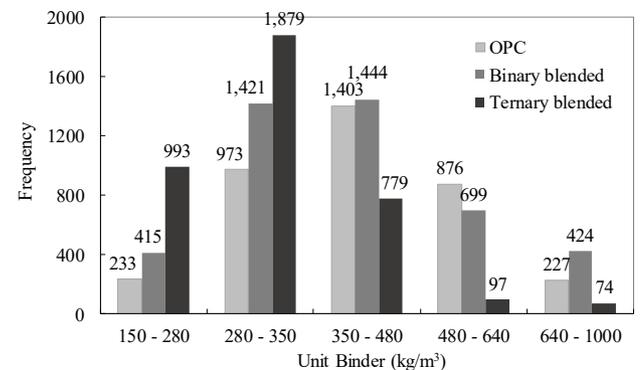
1) OPC: ordinary Portland cement, FA: fly ash, GGBS: ground granulated blast furnace slag, SF: silica fume



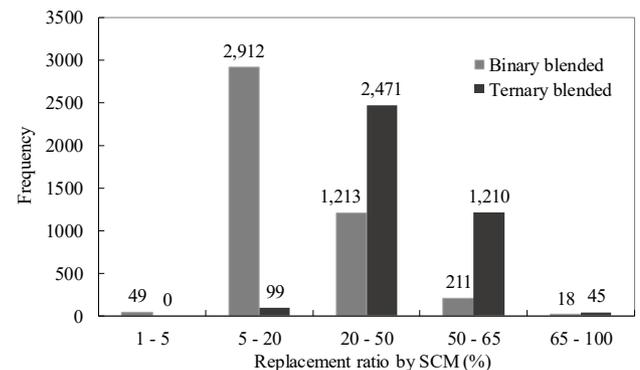
(a) 28-day compressive strength



(b) Water-to-binder ratio



(c) Unit binder contents



(d) Replacement ratio by supplementary cementitious materials (%)

Figure 1. Distribution of main parameters in database

2. 전산모델 프로그램 및 SQL 서버 구축

2.1 프로그램(서버) 개요 및 구성

본 연구에서 제안된 콘크리트 강도 및 최적 배합 예측 알고리즘은 C# 언어를 이용하여 Windows 어플리케이션으로 구현하였다. 이를 통해 사용자가 입력한 배합정보를 기반으로 콘크리트 강도를 예측하거나 요구 강도에 따른 최적 배합을 제시하는 기능이 개발되었다. 콘크리트 배합 정보 수집 서버는 Windows 10 기반 인터넷 정보서비스 (IIS, Internet Information Service) 기능을 통해 활성화되며, 사용자가 설치한 프로그램으로부터 전송된 콘크리트 배합정보는 ASP.Net WebAPI Restful Service 어플리케이션을 통해 메인 서버에 저장되고 필요에 따라 Excel 포맷으로 전환될 수 있다. 또한, 서버로 수집된 데이터는 확장 혹은 공유를 위해 Microsoft SQL Servers Express 로컬 데이터베이스에 저장됨으로서, 타 DB 서버로의 변환이나 Microsoft SQL Servers를 통해 쉽게 서비스할 수 있도록 구성되었다(Figure 2).

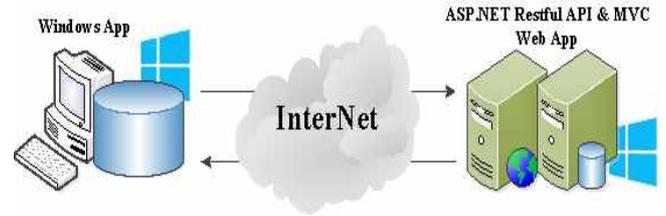


Figure 2. System overview

프로그램은 크게 두 가지 목적으로 운영되도록 하였다. 첫 번째는 사용자가 최적의 설계 배합과 재령별 강도 등을 직접 평가할 수 있도록 서비스를 제공하는데 있으며, 두 번째는 사용자가 예측을 위해 입력한 재료특성이나 배합 그리고 실험결과 등을 메인 서버에 저장되도록 하여 지속가능한 DB 수집방식을 구축하는데 있다. 이를 위해서는 사용자에게 대한 건설 구조물 및 콘크리트 품질관리의 다양한 접근 및 서비스가 제공되어야 한다. 해당 시스템은 운용이 매우 직관적이며 해당 분야의 전문가 외에도 운용이 가능하도록 설계되어 접근성이 높은 특징을 갖는다.

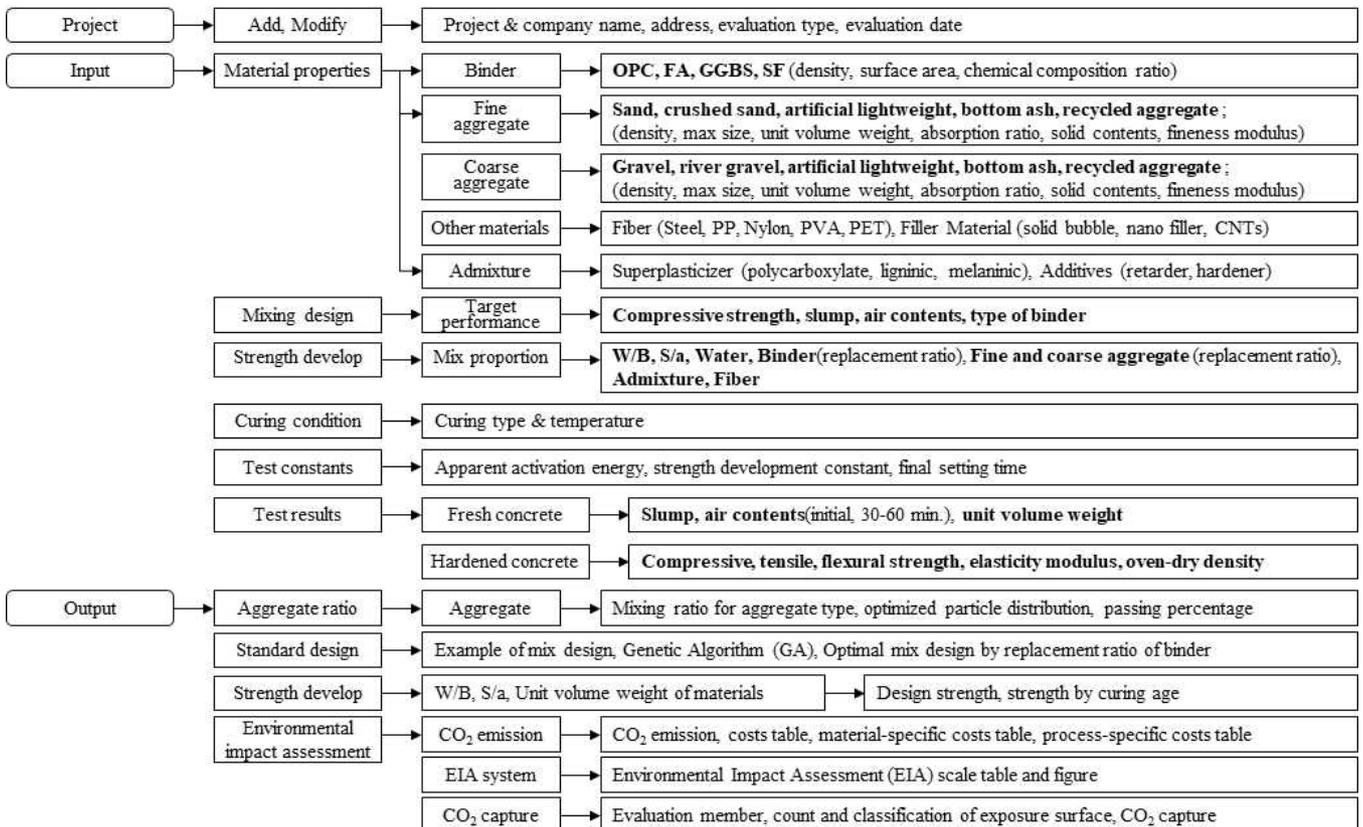


Figure 3. Distribution of main parameters in database

2.2 메뉴 구조

Figure 3에 나타난 사용자 프로그램 메뉴는 프로젝트 설정과 입력, 평가로 구성된다. 먼저 프로젝트는 목표성능을 충족할 수 있는 최적 배합설계를 제공하는 ‘배합설계’ 탭과 사용자에게 의해 입력된 시방 배합의 압축강도와 환경영향 등의 예측 결과를 제공하는 ‘강도발현’ 탭으로 나뉜다. 사용목적에 맞는 프로젝트 유형을 선택한 후 사용재료의 특성 및 배합인자를 입력하는 방식이다. 입력 탭(Figure 4)에서는 재료특성, 목표성능(혹은 배합표), 양생조건, 실험상수 그리고 실험결과를 입력할 수 있다. 사용자는 어떠한 프로젝트를 선택하더라도 재료특성을 입력해야 하며, 자체 실험값이 없는 경우 시스템에 입력된 기본 값(default)을 그대로 사용할 수 있다. 재료특성에서 사용자에게 의해 입력된 값은 강도예측이나 배합설계 그리고 골재의 최적 입도분석을 수행하는 데 사용되며, 입력 즉시 해당 값은 콘크리트 배합 DB로 축적된다. 사용자 프로그램의 전체 메뉴 구조를 Figure 3에 나타내었다. 서버용 프로그램은 사용자 프로그램에 의해 취득된 데이터를 확인하고 필요한 경우 Excel 파일로 저장될 수 있다.

2.3 웹(SQL) 기반 DB 수집 구조

SQL 기반 데이터 수집의 개념적 정보 모델은 사용자의 콘크리트 배합정보, 결합재 및 골재 정보, 강도예측을 위한 학습데이터 등으로 대표되는 사용자 정보 모델과 서버에 저장되는 서버 정보 모델로 구성된다.

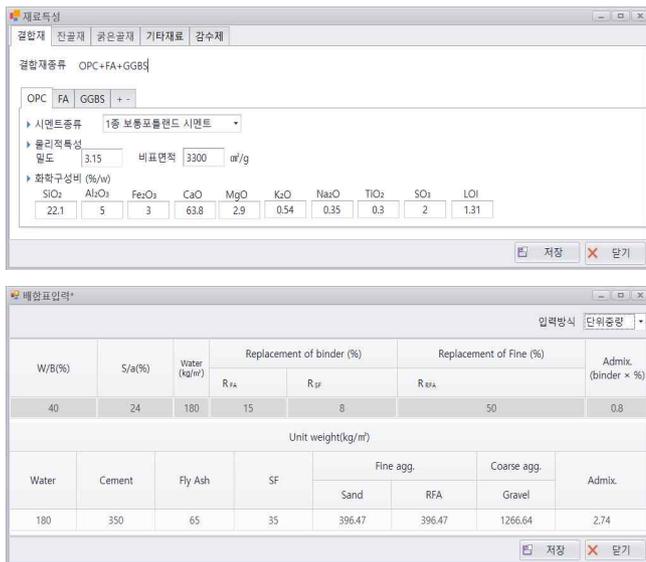


Figure 4. Example of input window

Table 1. Database collection factors in the developed program

Type	Collection factors
Binder	Density, Surface area, Chemical composition,
Raw material	Aggregate Type(e.g. natural, lightweight, recycled), Density(oven-dried, saturated), Water absorption, Fineness modulus
	other Reinforcing fiber (steel, PP, PVA, PET), Filler material (solid bubble, nano filler, carbon nano-tube)
Mixture proportion	W/B, S/a, Unit weight of contents, Replacement ratio of binder and aggregate
Curing condition	Temperature (equivalent, elevated)
Performance of Fresh concrete	Initial slump, Air contents, Unit volume weight
Performance of Hardened concrete	Strength(Compressive, tensile, flexural), Elasticity modulus, Strain at peak, Poisson's ratio, Oven-dry density

DB로 수집될 콘크리트 배합정보 및 성능결과 등의 항목은 Table 1과 같다. 사용재료의 종류는 향후 신재료 및 공법의 개발에 따라 추가될 수 있도록 설계하였으며, 현재 적용된 결합재 종류는 보통 포틀랜드시멘트와 고로슬래그 미분말, 플라이애시 그리고 실리카폼이다. 잔골재는 모래(S), 부순모래(CS), 인공경량(ALFA), 저회경량(BFA), 순환 잔골재(RFA)가 포함되며, 굵은골재는 쇠석(G), 강자갈(RG), 인공경량(ALCA), 저회경량(BCA) 그리고 순환 굵은골재(RCA)로 구성된다. 그 외에 보강 섬유나 혼화제의 종류 등 콘크리트 배합설계에 필요한 모든 변수가 수집항목에 포함(Table 1)되며, 향후 누적된 데이터를 기반으로 결합재, 골재특성에 따른 환경영향평가나 딥러닝 분석 등 다양한 적용이 가능할 것으로 사료된다.

3. 인공신경망 기반 콘크리트 강도 예측

3.1 Perceptron 기반 인공신경망 기본 개념

인공신경망 모델(ANN)은 생물학적 신경망의 특성을 반영하여 모호화한 것으로 학습데이터를 이용한 훈련과정을 거쳐 데이터에 숨어 있는 패턴을 찾아내는 모델링 기법이다. 따라서 이는 주로 연산이 많고 복잡한 문제를 해결하거나 다수의 DB를 기반으로 변수별 가중치를 찾아내는 것을 목적으로 한다[5].

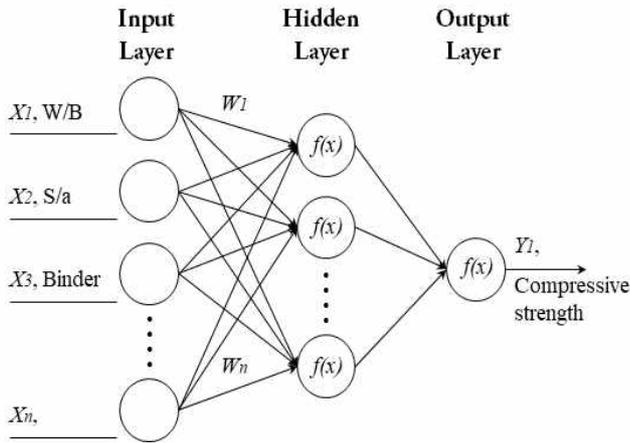


Figure 5. Diagram of ANN model

Figure 5에 나타난 바와 같이 W/B나 S/a 등의 배합설계 인자 값을 기반으로 각각의 가중치($W_1, W_2 \dots W_n$)를 적용하는 은닉층(hidden layer)을 거쳐 출력층(output layer)에 도달한다. 이처럼 다층신경망은 주어진 입력과 은닉층의 관계를 각각의 가중치(weight)의 곱으로 산출하며, 이 방법은 순전파(feed forward)에 해당한다. 이후 순전파에 의한 출력 값과 입력자료의 목표 값 간의 오차가 계산되고, 기존 가중치와의 오차 기울기를 계산하여 학습률을 곱하는 연산을 수행, 가중치를 갱신하게 되는데 이를 역전파(back propagation) 연산이라 칭한다. 학습 데이터를 기반으로 각 층에서 사용하는 가중치를 갱신하는 과정이 곧 학습이다.

$$S(x) = \frac{1}{1 + e^{-x}} \quad (1)$$

학습이 종료된 후 순전파 연산 과정을 통해 출력 값이 도출되며, 은닉층과 출력층의 활성화 함수는 시그모이드 전이 함수(식 1)가 주로 사용된다. 연구에서는 시그모이드 함수의 하나인 로지스틱 함수가 적용되었다.

3.2 인공신경망 기반 콘크리트 강도 예측

콘크리트의 압축강도에 영향을 미치는 변수는 결합재 종류나 W/C, 경량골재 사용여부 등으로 매우 다양하게 설계 될 수 있으나, 각 변수별 가중치는 큰 차이를 나타낸다. 따라서 다수 연구에서는 인자별 가중치를 정량화하며 압축강도를 예측하는 수치 모델을 제안하고 있으며, 이러한 노력은 결과적으로 구조물의 품질관리 및 구조해석을

용이하게 한다. 그러나 제안 방정식을 통한 예측 프로세스는 개별 연구자가 제안하는 사용재료나 배합변수 및 환경조건에 적합한 것이며, 이에 범용적으로 활용되기에는 어려움이 있다. 이러한 개념에서 콘크리트 강도 예측을 위해 적용되는 다층 퍼셉트론 ANN은 다수의 dataset에 기반해 입-출력 변수의 관계를 학습을 통해 정의한다. 입력변수는 콘크리트 설계 인자이며 학습의 상세 변수는 Table 2와 같다.

Table 2. Details of input and output values in each stage

Type	Variable definition	Unit	Range
Output	Compressive strength	MPa	10.1 - 166.8
	W/B	%	12.5 - 78.9
	S/a	%	20.4 - 68.9
	Unit water contents	kg/m ³	97 - 247.5
	Replacement ratio by		
Input	FA	%	0 - 55
	GGBS	%	0 - 80
	SF	%	0 - 30

Figure 6은 ANN을 이용한 압축강도 예측 과정을 요약한 것이다. 사용자가 시스템에 재료특성을 비롯한 배합설계 인자를 입력하여 평가를 수행할 시, 입력 값에 상응하는 학습용 데이터의 유무를 평가한 후 결과 값을 도출한다. 이 때 사용자 입력 값이 기존 데이터의 범위를 벗어나거나 유사 값이 충분하지 않은 경우 W/B와 각 혼화재의 치환율에 따른 예측식(식 2)을 적용해 결과가 산출될 수 있다. 적용된 식은 이전 연구에서 11,941개의 동일한 DB를 기반으로 회귀분석을 통해 제안된 바 있으며, Mun[6]에 따르면 이는 결정계수(R^2) 0.79 수준의 정확도를 가지고 있다.

$$\frac{f_{ck}}{f_0} = 1.37 \left[(W/B)^{-1} \left\{ 1 + (R_f + R_G^{4.0} - R_S^{0.7}) \right\} (T/20)^{-0.1} \right] \quad (2)$$

f_0 : 압축강도 참고 값 (= 10MPa)

R_f, R_G, R_S : FA, GGBS, SF 치환율 (%)

T : 양생온도 (°C)

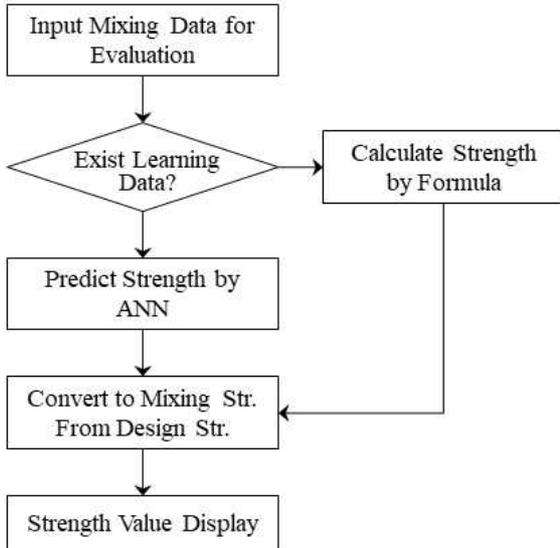


Figure 6. Evaluation process by ANN

3.3 인공신경망 예측 결과

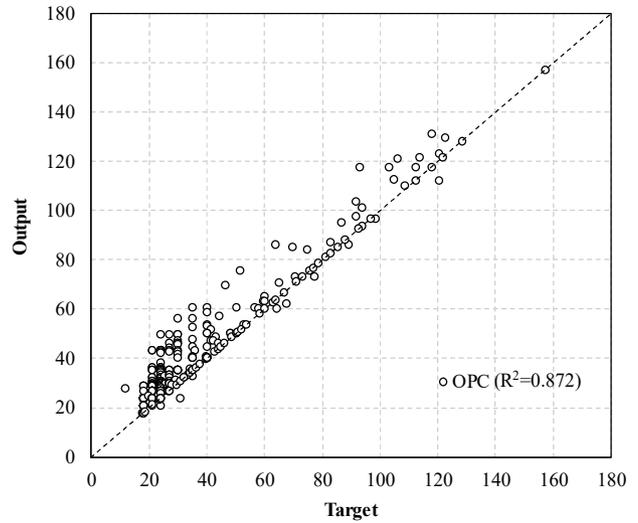
본 예측에서는 6개의 입력변수를 활용하여 총 데이터의 약 90%에 해당하는 10776개의 배합 입력 데이터를 학습용으로 사용했으며, 약 10%에 해당하는 1165개를 테스트용으로 구분하였다. 배합 데이터는 Figure 1에 나타낸 바와 같이 결합재의 종류(1~3성분계)에 따라 대체로 균등하게 나뉘지며 이러한 비율은 학습 및 테스트용 데이터를 분류하는데도 동일하게 적용하였다. 학습의 은닉층 수는 5, 각 테스트에 대한 데이터 검색 범위는 10%, 최대 학습 횟수(maximum epochs)는 500번으로 각각 설정하였다. 학습자료와 입·출력 변수를 ANN에 입력하고 학습 정지 후 1165개의 평가 대상에 대한 목표 값, 출력 값 및 오차율을 W/B의 범위별로 평균하여 Table 3에 나타냈다. 또한 모델 검증과정에서 얻어진 예측결과(output)와 목표 값(target)과의 관계가 결합재의 종류에 따라 Figure 7에 나타나 있다. 동일 그림에 치환된 결합재의 종류에 따른 결정계수를 표시하였다.

평가용 자료의 오차율 및 평균 오차율(mean error rate) 산출을 위해 아래 (식 3, 4)가 적용하였다.

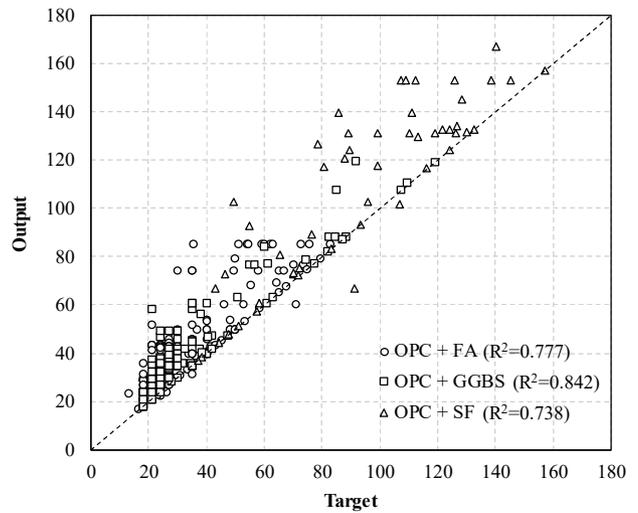
$$Error(\%) = \frac{|T - O_A|}{T} \times 100 \quad (3)$$

T : 목표 값 (Target value)

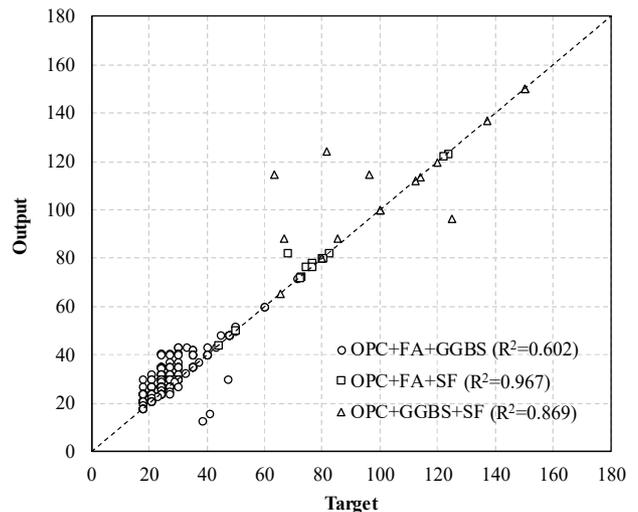
O_A : 출력 값 (Actual output value)



(a) Ordinary Portland cement



(b) Binary blended cement



(c) Ternary blended cement

Figure 7. Output versus target values of ANN test sets

Table 3. Compressive strength estimation by ANN model

No.	Ordinary Portland cement			Binary blended cement			Ternary blended cement		
	15 ≤ W/B < 40	40 ≤ W/B < 55	55 ≤ W/B < 80	15 ≤ W/B < 40	40 ≤ W/B < 55	55 ≤ W/B < 80	15 ≤ W/B < 40	40 ≤ W/B < 55	55 ≤ W/B < 80
Mean target value (MPa)	69.0	26.6	20.1	77.6	31.7	23.7	49.9	24.6	20.7
Mean output value (MPa)	72.1	29.4	23.4	85.4	36.2	27.9	51.5	26.8	22.4
Mean error rate (%)	4.29	6.12	8.79	10.01	14.20	17.54	3.32	8.92	8.14

$$MER(\%) = \left(\sum_{i=1}^n |Error_i| \right) / n \text{ ----- (4)}$$

MER : 평균 오차율 (Mean error rate)

평가 결과 결합재 종류나 W/B를 막론하고 출력 값은 목표 값을 대체로 과대평가하고 있으며, 평균적으로 약 9.1% 가량 높은 값을 도출하고 있다. 결합재의 종류에 따라서는 1성분계와 3성분계가 상대적으로 평균 R²가 높게 나타났으며, 강도 범위에 따라서는 W/B가 높을수록 즉, 목표 강도의 범위가 낮아질수록 평균 오차율은 다소 증가 되는 것으로 나타났다. Table 3에 보는 바와 같이 W/B 및 결합재 종류에 따른 평균 오차율은 최소 4.29%에서 최대 17.54%까지 나타났으며, 전체 테스트 데이터의 평균 오차율은 약 10.8%로 나타나 정확도는 89.2%로 나타났다.

Figure 7을 통한 분석 결과 본 모델의 결정계수는 0.884로 기존의 ANN 모델에 비해서는 다소 낮은 상관성을 보였다. 이는 콘크리트 배합실험을 통해 측정되는 실험 값 즉, 강도 목표 값이 실험환경이나 실험자에 따라 비교적 높은 편차를 갖게 되며, 동일한 배합이라 할지라도 시편의 강도 시험 값은 대략 10-15% 내외의 오차를 나타낼 수 있다는 점을 감안할 필요가 있다. 결과적으로 콘크리트 강도 예측에는 안전율이 요구되며 이는 Figure 8과 같이 콘크리트 배합강도로 표시된다.



Figure 8. Example of output window of compressive strength

4. 결 론

연구에서는 건설 품질관리나 최적 배합설계 등 콘크리트와 관련된 대부분의 정보 및 데이터를 수집 및 분석하여 배포할 수 있는 웹(SQL) 기반 프로그램을 개발하고 서버 구축개요 및 시스템에 탑재된 인공지능망 알고리즘에 관해 고찰하였다. 다수의 콘크리트 배합 DB를 기반으로 설계 인자를 입력변수로 설정해 압축강도 예측 모델을 검증한 결과는 다음과 같다.

- 1) 국내·외에서 발표된 논문과 자체 실험결과 그리고 레미콘 배합정보를 토대로 총 11,941개의 DB를 구축하였다. W/B 범위는 15-80%, 결합재 종류는 1~3성분계로 분류되며, 현재 연구 및 레미콘 적용 배합의 추세를 대략적으로 반영한다.
- 2) 개발된 프로그램은 콘크리트 구성재료의 특성, 배합 정보, 그에 따른 성능발현 등 콘크리트와 관련된 대부분의 정보를 제공한다. 특히 사용자에게 의해 입력된 데이터는 메인 서버로 다시 저장되어 지속가능한 DB 수집이 가능하며 사용빈도가 증가될수록 예측의 신뢰도가 상승되는 구조를 갖는다.
- 3) 콘크리트 배합 인자(W/B, S/a, W, R_F, R_G 및 R_S)를 입력변수로 설정해 제안한 인공지능망 모델을 적용하여 결과 값인 콘크리트 압축강도를 도출한 결과, 목표 값에 비해 대체로 높은 경향을 나타냈다. W/B 나 결합재 종류에 따른 정확도는 평균 82.5~95.7% 가량이며, 전체 데이터의 정확도는 평균 89.2% 수준으로 나타났다.

개발된 프로그램은 인공지능망을 활용한 강도 예측 외에도 재료 및 부재 특성에 기반한 전과정 환경평가와 골재의 체통과율에 따른 입도분포 최적 혼합비율제시 등 콘크리트 분야의 다양한 서비스를 제공한다. 다만 다양한 환경변수의 추가적 검토나 강도 예측의 정확도를 상승시

키는 등의 과제는 향후 개선이 필요한 항목으로 보인다.

요 약

콘크리트의 품질관리는 주로 압축강도의 예측과 제어를 뜻한다. 이를 위해 관련 업계에서는 콘크리트 배합설계 및 재령별 강도에 관한 상당수의 데이터베이스를 구축하고 있으나, 기술유출 등의 이유로 공유되지 못해 결과적으로 품질관리를 위한 비용과 노력은 과도하게 낭비되고 있다. 본 연구에서는 웹 기반 전산모델 프로그램을 개발하여 사용자에게 콘크리트의 강도 예측 결과를 비롯한 다양한 최적 값을 제시하고, 사용자가 입력한 배합특성과 결과는 다시 DB로 수집될 수 있도록 유도하는 지속가능한 DB 수집 시스템을 구축한다. 해당 프로그램은 콘크리트 관련 전반적 기술을 다루고 있으며, 특히 압축강도의 예측은 다수의 DB를 기반으로 모델링된 인공신경망 기법을 적용하여 평균 89.2% 수준의 정확도에서 예측 값을 제공한다.

키워드 : 구조적 질의어, 인공신경망, 콘크리트 압축강도, 데이터베이스

Funding

Not applicable

Acknowledgement

This work was supported by the GRRC program of Gyeonggi province. [GRRC KGU 2020-B01, Research on Intelligent Industrial Data Analytics]

ORCID

Lee, Goon-Jae, <https://orcid.org/0000-0002-5212-7965>

Kim, Hak-Young, <https://orcid.org/0000-0001-5141-2775>

Lee, Hye-Jin, <https://orcid.org/0000-0002-0210-3092>

Hwang, Seung-Hyeon, <https://orcid.org/0000-0003-3994-3404>

Yang, Keun-Hyeok, <https://orcid.org/0000-0001-5415-6455>

References

1. Aroso ME, Aroso MH. Reducing costs through concrete quality control. *Innovative Housing Practices: Better Housing Through Innovative Technology and Financing*. 1989;265-70. <https://doi.org/10.1016/B978-0-08-037884-8.50045-7>
2. Song J, Yu JH, Kim K. On-site quality control support tools based on mobile BIM-focusing on quality management work. *Korean Journal of Construction Engineering and Management*. 2020;21(6): 27-37. <https://doi.org/10.6106/KJCEM.2020.21.6.027>
3. Nikbin IM, Rahimi R S, Allahyari H, Damadi M. A comprehensive analytical study on the mechanical properties of concrete containing waste bottom ash as natural aggregate replacement. *Construction and Building Materials*. 2016 Sep;121:746-59. <https://doi.org/10.1016/j.conbuildmat.2016.06.078>
4. Ji GB, Mun JH, Yang KH. Evaluation of mechanical properties of lightweight concrete using bottom ash aggregates and foam. *Journal of the Korea Concrete Institute*. 2019 Aug;31(4):375-84. <https://doi.org/10.4334/JKCI.2019.31.4.375>
5. Cherkassky V, Filip M. *Learning from data: concepts, theory, and methods*. 1st ed. New York: John Wiley & Sons; 2007. 560 p.
6. Mun JS. Generalized model for compressive strength development of concrete considering the addition of supplementary cementitious materials and curing temperatures. [dissertation]. [Suwon (Korea)]: Kyonggi University; 2016. 168 p.