

인공신경망을 이용한 콘크리트 강도 추정

Prediction of Concrete Strength Using Artificial Neural Networks

이승창^{*} 안정찬^{**} 정문영^{***} 임재홍^{****}
Lee, Seung Chang An, Jung Chan Jung, Moon Young Lim, Jae Hong

ABSTRACT

Traditional prediction models have been developed with a fixed equation form based on the limited number of data and parameters. If new data is quite different from original data, then the model should update not only its coefficients but also its equation form. However, artificial neural network (ANN) does not need a specific equation form. Instead of that, it needs enough input-output data. Also, it can continuously re-train the new data, so that it can conveniently adapt to new data. Therefore, the purpose of this paper is to develop the I-PreConS (Intelligent system for PREdiction of CONcrete Strength using ANN) that provides in-place strength information of the concrete to facilitate concrete form removal and scheduling for construction.

1. 서론

콘크리트 공시체의 강도를 추정하는 종래의 기술로는 단순 시험에 의한 방법, 온도와 재령의 함수인 적산온도를 이용하는 방법, 마이크로파를 이용하는 방법 등이 있다. 현재까지 이러한 방법들을 기반으로 수많은 연구자들에 의해 다양한 추정 방법(식)이 제시되어 왔다. 일반적으로 이러한 기존 강도 추정법은 특정 영향 인자 1~3개 정도만을 변수로 고려하여 제시되어 왔다. 예를 들어, 적산 온도를 이용하여 콘크리트 강도를 추정하는 경우, 2개의 영향인자(물 결합재비와 평균 양생 온도)만을 고려하여 강도를 추정한다.

이와 같이 기존의 추정 방법은 특정 변수만을 고려하고 제한된 데이터를 기반으로 하고 있어, 유사성이 적은 새로운 조건(또는 환경)에서의 추정 정확도가 매우 낮기 때문에 실용적(실무 또는 현장)으로 사용하는 데 한계가 있다. 또한, 외국에서 제안된 식은 국내 건설재료나 환경을 고려하지 못한다.

본 연구에서는 전술한 종래 기술의 한계와 문제점을 해결하고자, 인공지능기술의 하나인 인공신경망을 이용하여 동시에 다양한 영향인자(변수)를 고려하고, 학습된 데이터에 의해 추정함으로써 경험적 지식을 객관화시키고, 새로운 데이터를 계속적으로 재학습하여 환경적 변화에 능동적으로 적용할 수 있는 시스템을 개발하고자 하였다.

따라서, 본 연구의 목적은 현장에서의 거푸집 탈형 시기 조정(최적화), 지주 제거 시기 결정, 공사 일정 수립 및 조정을 위하여 인공지능기술(인공 신경망)을 응용하여 조기(16시간 이후)에 콘크리트 공시체의 압축 강도를 추정하는 시스템(I-PreConS, Intelligent PREdiction system of CONcrete Strength)을 개발하는데 있다.

2. 인공 신경망 모델

콘크리트 강도 예측을 위한 신경망 알고리즘으로는 다변수 비선형 문제에 가장 적합하고 대표적인 오

* 정회원, 현대산업개발 기술연구소, 과장, 공학박사

** 정회원, 현대산업개발 기술연구소, 과장

*** 정회원, 현대산업개발 기술연구소, 부장

**** 정회원, 현대산업개발 기술연구소, 소장

○ 본 논문의 내용은 특허출원 제2002-11594호의 일부임.

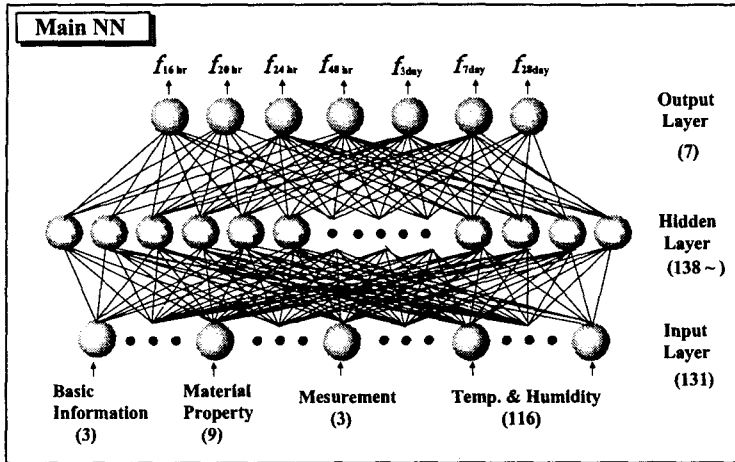


그림 1 인공 신경망 구조

류 역전파 학습 알고리즘(Error Back-propagation Training Algorithm)을 이용하였다. 이 알고리즘을 바탕으로 저자가 기존에 제안한 구조 해석을 위한 신경망 모델 개발 단계를 기본으로 하여 신경망 모델을 개발하였다.

3. 신경망 모델 개발 단계

3.1 입력층 뉴런수 결정(단계 1)

콘크리트 강도에 영향을 미치는 요인으로부터 신경망의 입력층 뉴런 수를 결정한다. 콘크리트 강도에 영향을 미치는 요인을 열거하면 상당히 많다. 이와 같이 영향인자(Parameter, 변수)가 많은 경우에는 학습패턴 수가 과도하게 필요하여 현실적으로 시뮬레이션이 불가능하거나, 어느 정도의 오차를 허용하는 공학적인 문제를 푸는데 있어 비실용적일 수 있다. 따라서 초기 개발 단계에서는 표 1과 같이 크게 4가지(기본 정보, 재료, 측정 항목, 대기 온/습도)로 분류하여, 기본 정보 3개(타설 시점은 온/습도 조건으로 대체, 타설 지역은 동일하므로 제외), 재료 9개, 측정항목 3개, 대기 온/습도 116개(타설일부터 타설 후 28일까지)로 총 131개의 변수를 입력 뉴런으로 초기 가정하였다.

3.2 출력층 뉴런수 결정(단계 2)

본 시스템에서 추정하고자 하는 콘크리트 강도는 재령에 따라 증가한다. 현장에서의 거푸집 탈형시기 및 지주제거 시기를 판정하기 위한 자료를 제공하기 위하여 초기 재령(타설 후 3일 이내)을 중심으로 7재령(16시간/20시간/24시간/2일/3일/7일/28일)으로 결정하였다. 따라서, 출력층 뉴런수를 7개로 결정하였다.

3.3 학습 패턴 생성(단계 3)

학습 패턴 생성을 위해서 공시체 제작 및 압축강도 시험을 수행하였다. 표준적인 학습 패턴생성(공시체 제작 및 시험)은 경기도 광주 소재 A 레미콘 회사 협조로 현대산업개발 기술 연구소 실험동에서 이루어졌다. 현장 조건과 유사하도록 타설 후 24시간 동안에는 현장에서 보양을 한다는 가정하에 동해를 입지 않도록 실험실 양생(평균 온도 10℃ 이상)을 하였다. 또한, 24시간 이후에는 직사 광선을 피할 수 있는 장소에서 대기 양생을 하였다. 표 1은 2001년 9월부터 2002년 2월까지 생성한 총 24개의 학습 패턴을 보여 주고 있다.

3.4 신경망 변수 결정(단계 4)

학습패턴을 0.9 이하가 되도록 스케일링 하였으며, 최대 허용 에러(Emax)는 저자의 이전 경험으로부

터 $1E-03$ 으로 결정하였다. 그림 1과 같이 은닉층의 수는 1로, 은닉층 뉴런 수는 입력과 출력층 뉴런 수의 합을 최소값으로 초기 가정하였다. 학습의 반복회수는 활성화함수(unipolar 시그모이드 함수로 가정)의 경사도 계수 λ , 학습 상수(η), 모멘텀 항(α)에 좌우된다. 본 모델에서는 일반적인 문제에 적용 가능하도록 $\lambda=1.0$, $\alpha=0.1$, $\eta=0.5$ 로 초기 가정하였다.

3.5 학습 완료 및 테스트(단계 5)

전 단계로 결정한 신경망 구조(그림 1)로 반복 회수(epoch) 1만회 정도에서 학습을 완료하였다. 학습된 데이터를 테스트 패턴으로 리콜한 결과, 신경망의 출력값과 기대 출력값(시험값)과의 오차가 $\pm 10\%$ 이내로 나타나 충분히 학습된 신경망임을 확인하였다.

4. 시뮬레이션 결과 및 분석

4.1 테스트 패턴

신경망 모델의 추정도를 판정하고, 향상된 신경망 모델을 개발하기 위하여 표 2와 같이 4개의 테스트 패턴으로 평가하였다. 테스트 패턴은 학습에 사용하지 않은 시험 결과값으로서 표 2(끝 부분)와 같은 특성을 가진다.

4.2 테스트 패턴별 결과 분석

3절에서 설명한 신경망 구조와 학습 패턴으로, 4.1의 테스트 패턴을 리콜한 결과는 그림 2와 같다. 회귀분석의 결과의 오차를 정량화 하기 위해서는 추정 결과에 대한 결정 계수(coefficient of determination)를 구하여 분석할 필요가 있다. 결정 계수가 0.9라는 의미는 추정 결과가 시험 결과를 90% 정도 설명할 수 있음을 의미한다.

4.2.1 기존 방법과 비교

기존 강도 추정 방법으로 대표적인 적산 온도를 이용한 추정식(이하, 적산 온도 방식이라함)으로부터의 추정 결과와 비교하였다. 참고 문헌에서 사용한 회귀 분석 데이터와 본 연구에서 사용한 학습 데이터가 상이하므로, 적산 온도 방식에 의한 결과와 인공 신경망에 의한 결과를 단순 비교한다는 것에 무리가 있을 수 있지만, 추정 결과를 실용적으로 사용할 수 있는가를 판단하는 것은 가능하다. 기존 문헌으로부터 적산 온도 방식에 의한 추정식과 계수를 이용하여 테스트 패턴에 적용한 결과는 그림 2의 tp1, tp2와 같다. 일반 강도(tp1, tp2)에서는 적산온도 방식을 적용할 수 있는 문헌을 찾을 수 있었으나, 일반 강도가 아닌 경우(tp3, tp4)에는 동일한 강도(500, 350)를 사용한 문헌을 찾을 수 없었고, 유사한 강도 데이터를 이용한 적산온도 방식을 적용하였을 경우에는 결정계수가 매우 낮기 때문에 비교에서 제외하였다.

일반 강도(tp1, tp2)의 경우에도 물결합재비와 양생기간의 평균온도만을 입력값으로 하기 때문에 결정계수가 0.8 이하로 추정 정도가 상당히 떨어짐을 알 수 있다. 따라서, 적산 온도 방식을 이용한 기존 문헌상의 자료로부터 테스트 패턴의 압축강도를 추정하기는 어려울 것으로 사료된다.

4.2.2 초기 인공 신경망 추정 결과 분석

신경망은 초기 연결 강도값에 따라 어느 정도 다른 결과를 보이므로, 표 3과 같이 3차례 시도에 의한 평균값으로 평균 결정 계수를 구하여 분석하고, 평균 결정 계수의 총합으로 추정도 평가 지수 개념을 적용하여 신경망 구조의 정확도를 정량화하였다.

표 3의 평균 결정 계수로부터 테스트 패턴 tp2와 tp3의 추정도(결정 계수 0.9 이상)가 상당히 높은 데 반하여, 테스트 패턴 tp1과 tp4의 추정도가 상당히 떨어짐을 알 수 있다. 표 2의 테스트 패턴의 특성과 비교해 보면, 본 시뮬레이션에서는 동일한 강도나 배합비 보다는 운습도 이력이 다른 경우(tp1, tp4)에 추정 정도가 낮으므로 이에 대한 보완이 필요하다.

양생시의 대기 온/습도 이력을 효율적으로 학습하고, 초기 신경망 모델의 추정 정도를 높이기 위하여 다음절에서 설명할 변수 응축(condensation)과 입력 뉴런 가중(weighting) 기법을 적용하여 시뮬레이션 하였다.

4.3 양생 온/습도 변수 응축에 따른 시물레이션 결과

초기 신경망 모델에서는 대기 온/습도 관련 변수로 양생일 평균 온도/최고 온도/최저 온도/평균 습도, 즉 4개의 입력 뉴런을 고려하는 A(4) 패턴으로 학습을 수행하였다. 대기 온/습도 관련 변수를 4개에서 2개로 응축하여 양생일 평균 온도/평균 습도만 고려하는 B(2) 패턴, 기존 방식처럼 양생일 평균 온도만을 고려하는 C(1) 패턴으로 시물레이션을 수행하였다. 테스트 결과는 표 4와 같으며, B(2) 패턴이 추정도 평가 지수에서 가장 높게 나타나고 있다. 따라서, 신경망 모델에서 대기 온/습도 변수로는 양생일 평균 온도/평균 습도를 고려하는 것이 추정도를 가장 높게 할 수 있다.

4.4 입력 뉴런(양생 온/습도) 가중에 따른 시물레이션 결과

본 연구에서는 추정도를 높이는 다른 방법으로 가중(weighting) 뉴런을 적용하였다. 이 방법은 입력 뉴런들 중 결과값에 미치는 영향 정도가 다른 경우, 중요도에 따라 입력 뉴런을 반복함으로써 가중하는 방법이다. 즉, 시멘트의 수화 반응이 일어나는 응결 시간(콘크리트 타설 후 1시간~10시간)에 해당하는 타설일의 온/습도에는 두번 반복 가중하고, 초기 재령에 해당하는 타설 후 1~2일에는 한번 가중하였다.

입력 뉴런 가중에 따른 시물레이션 결과는 표 5와 같으며, W-IV 패턴, 즉 타설일 온/습도 개별 6개 뉴런 가중 및 타설 후 1~2일에는 3개 뉴런 가중이 가장 좋은 결과를 보였다. 특히, 입력 뉴런의 가중에 따라 초기 강도의 추정도가 증가하였음을 알 수 있다. 그러므로, 신경망 모델에서 초기(타설 후 3일 까지) 강도의 추정도를 높이는 방법으로 입력 뉴런의 가중 기법이 매우 유효한 것으로 판단된다.

4.5 최종적인 시물레이션 결과

전술한 변수 응축(4.3절)과 입력 뉴런 가중(4.4절)에 따른 최종적인 신경망 모델의 추정 결과는 그림 3 및 표 6과 같다. 초기 신경망 모델의 추정 결과(그림 2, 표 3)와 비교하여 추정도 평가 지수는 3.35에서 3.72로 증가하였으며, 평균 결정 계수는 모든 테스트 패턴에서 0.9 이상의 상당히 좋은 결과를 보였다.

5. 결 론

본 연구는 인공신경망을 이용하여 콘크리트 강도를 조기에 추정하는 시스템을 개발한 것으로, 다양한 시물레이션과 결과 분석을 통하여 다음과 같은 결론을 얻었다.

1. 본 연구에서 제시한 시험 데이터에 한정하여, 인공 신경망 모델(I-PreConS)이 적산 온도 방식에 비하여 높은 추정도를 보였다.
2. 콘크리트 강도 추정용 인공 신경망 모델 개발시, 변수 응축 기법을 적용하여 대기 온/습도 변수 중에서 양생일 평균 온도와 평균 습도만을 고려하는 것이 가장 효율적이다.
3. 신경망 모델에서 콘크리트의 초기(3일 이내) 강도를 추정하기 위해서는 입력 뉴런 가중 기법을 적용하는 것이 매우 효과적이다.

참고문헌

1. Lee S.C., Park S.K., Lee B.H., "Development of the Approximate Analytical Model for the Stub-girder System Using Neural Networks," Computers & Structures 2001;79(10):pp 1013-1025.
2. 한천구, 한민철, "콘크리트의 강도 증진 해석에 의한 측면 거푸집 존치 기간 산정," 대한건축학회 논문집, 구조계 17권 6호, 2001.6, pp87-94.
3. 길배수, 권영진, 남재현, 김무한, "적산온도방식에 의한 콘크리트의 압축강도 증진해석에 관한 실험적 연구," 대한건축학회 논문집, 구조계 14권 12호(통권 122호), 1998.12, pp 103-110.

표 1 학습 패턴

패턴 번호	입력값																		
	기본 정보							재료								측정			
	a	b	c	d	e	f	g	h	i	j	k	l	m	n	o	p	q	r	s
p1	아주	210	30	경기	9	13	16	183	보통	294	FA	40	890	864	대하	1	23	1.8	26
p2	아주	210	30	경기	9	25	15	176	보통	282	FA	39	887	897	대하	1	20	3.4	27
p3	아주	240	40	경기	9	25	17	182	보통	315	FA	43	867	870	대하	1.1	21	4.5	26
~	~																		
p24	아주	210	30	경기	1	9	16	183	보통	301	FA	33	890	864	대하	1	18	5.5	17

a:레이콘 회사, b:설계기준강도(kgf/cm²), c:운반시간(분), d:타설지역, e:타설시점(월), f:타설시점(일), g:타설시점(시), h:단위수량(kg/m³), i:시멘트 종류, j:시멘트 단위중량(kg/m³), k:혼화제 종류, l:혼화제 단위중량(kg/m³), m:단위세골재량(kg/m³), n:단위조골재량(kg/m³), o:혼화제 종류, p:혼화제 단위중량(kg/m³), q:슬럼프값(cm), r:공기량(%), s:근지않은 콘크리트 온도(°C)

패턴 번호	입력값(대기 온/습도)								기대 출력값								
	타설일				~	타설 후 28일				압축강도 시험 결과(kgf/cm ² , 대기 양생)							
	a	b	c	d	~	a	b	c	d	16h	20h	24h	48h	3일	7일	28일	
p1	25	20	26	62	~	14	11	24	73	32.3	45.0	58.0	114.0	146.0	223.3	247.6	
p2	23	20	25	65	~	14	9	25	70	26.7	27.8	38.0	70.2	90.5	125.2	165.9	
p3	23	20	25	65	~	14	9	25	70	23.5	29.6	36.0	70.9	93.0	138.7	163.3	
~	~																
p24	10	8	12	50	~	3.3	-1	9	76	10.1	13.9	19.2	33.2	55.0	123.0	179.9	

a:평균 온도(°C), b:최저 온도(°C), c:최고 온도(°C), d:평균 습도(%)

표 2 테스트 패턴

패턴 번호	입력값																		
	기본 정보							재료								측정			
	a	b	c	d	e	f	g	h	i	j	k	l	m	n	o	p	q	r	s
tp1	아주	210	40	경기	11	21	16	176	보통	289	FA	32	887	897	대하	1	15	5.5	23
tp2	아주	240	40	경기	10	22	16	182	보통	322	FA	36	867	870	대하	1.1	19	3.0	28
tp3	아주	500	40	경기	12	3	17	171	보통	493	FA	87	641	931	대하	9.9	23	1.4	26
tp4	아주	350	40	경기	11	26	17	165	보통	436	FA	33	792	928	대하	6.1	18	4.5	24

a~s: 표 1과 동일

패턴 번호	입력값(대기 온/습도)								기대 출력값								특성-학습 패턴과 비교			
	타설일				~	타설 후 28일				압축강도 시험 결과(kgf/cm ² , 대기 양생)								동일 강도	동일 배합비	동일 온습도이력
	a	b	c	d	~	a	b	c	d	16h	20h	24h	48h	3일	7일	28일				
tp1	15	13	17	45	~	-4	-9	7	68	13.1	18.2	22.4	35.6	63.6	93.5	150.3	多	○	×	
tp2	16	8	22	66	~	12	-1	17	65	20.0	22.8	28.7	62.9	88.8	160.0	195.7	少(유사多)	×	○	
tp3	15	13	17	45	~	-3	-10	1	84	33.0	46.0	71.6	134.7	179.1	266.7	375.5	少	○	○	
tp4	2	1	5	50	~	-2	-6	7	79	7.7	29.0	35.3	51.1	91.4	161.9	217.9	×	×	×	

a~d: 표 1과 동일

표 4 양생 온/습도 변수 응축에 따른 시뮬레이션 결과

	A(4)	B(2)	C(1)
평가지수	3.35	3.59	3.25

A(4): 양생일 평균온도/최고온도 /최저온도/평균습도
B(2): 양생일 평균온도/평균습도
C(1): 양생일 평균온도

표 5 입력 뉴런 가중 기법에 따른 시뮬레이션 결과

	W-I	W-II	W-III	W-IV	W-V	W-VI
평가지수	3.58	3.62	3.70	3.72	3.63	3.62
초기(3일) 평가지수	2.98	3.10	3.26	3.43	3.16	3.25

표4의 B(2) 학습 패턴을 기준으로 함.
W-I : 타설일(0일) 온/습도 연속 2.0 뉴런 가중, 타설 후 제 1 ~ 2일 1.0 뉴런 가중
W-II : 타설일(0일) 온/습도 개별 2.0 뉴런 가중, 타설 후 제 1 ~ 2일 1.0 뉴런 가중
W-III ~ VI : W-II와 동일 방식으로 2~5 배 추가 가중







그림 2 초기 신경망 모델의 추정 결과 및 기존 방법과의 비교

표 3. 초기 신경망 모델의 추정도 평가

	1차 시도	2차 시도	3차 시도	평균 결정 계수
tp1	0.80	0.86	0.64	0.77
tp2	0.97	0.97	0.93	0.96
tp3	0.93	0.98	0.98	0.96
tp4	0.59	0.67	0.71	0.66
*추정도 평가 지수 : 3.35				
*평가지수: 테스트 패턴별 평균 결정계수의 총합				







그림 3 최종적인 신경망 모델의 추정 결과

표 6. 최종적인 신경망 모델의 추정도 평가

	1차 시도	2차 시도	3차 시도	평균 결정 계수
tp1	0.91	0.95	0.90	0.92
tp2	0.97	0.98	0.88	0.94
tp3	0.97	0.92	0.97	0.95
tp4	0.88	0.89	0.96	0.91
*추정도 평가 지수 : 3.72				
*평가지수: 테스트 패턴별 평균 결정계수의 총합				