

다중 신경망을 이용한 콘크리트 강도 추정

Prediction of Concrete Strength Using Multiple Neural Networks

이승창*

Seung-Chang Lee

임재홍**

Jae-Hong Lim

ABSTRACT

In the previous study¹⁾, authors presented the I-PreConS (Intelligent PREdiction system of CONcrete Strength) using artificial neural networks (ANN) that provides in-place strength information of the concrete to facilitate concrete form removal and scheduling for construction. The serious problem of the system has occurred, which it cannot appropriately predict the concrete strength when the curing temperature of a curing day is changed. This is because it uses the single neural networks, which all nodes are fully connected, and thus it cannot smoothly respond for external impact. However this paper presents that the problem can be solved by multiple neural networks, which is composed of five ANNs.

1. 서론

콘크리트를 사용하는 건설 현장에서는 거푸집 탈형 시기 조정(최적화), 지주 제거 시기 결정, 공사 일정 수립 및 조정을 위하여 콘크리트의 압축 강도를 조기에 추정할 필요가 있다. 콘크리트 공시체의 강도를 추정하는 기술로는 적산 온도를 이용하는 방법(이하, 적산 온도 방식)이 가장 많이 사용되고 있다. 적산 온도 방식은 일반적으로 2개의 영향인자(물 결합재비와 평균 양생 온도)만을 가지고 추정하기 때문에 다양한 변수를 고려하지 못하고, 실제 상황의 대기 온/습도의 변화를 고려할 수 없는 한계를 가지고 있다.

저자들은 이러한 한계를 극복하기 위한 방안으로 콘크리트 강도 추정에 있어서 인공지능 기술의 하나인 인공 신경망(ANN, Artificial Neural Networks)을 이용하는 방법을 제안¹⁾한 바 있다. 참고 문헌¹⁾에서는 모든 변수를 하나의 신경망에서 고려하는 단일 신경망(Single ANN) 구조를 적용하여 콘크리트 강도를 추정하였다. 이러한 단일 신경망은 특정일의 온도만을 증가시켜 입력하였을 경우, 콘크리트 강도를 적절하게 추정하지 못하는 문제점을 가지고 있다. 이와 같은 단일 신경망의 문제점을 해결하고자 본 논문에서는 다중 신경망(Multiple ANN)²⁾ 구조를 사용하였다.

그러므로, 본 연구의 목적은 콘크리트 강도 추정에 있어서, 단일 신경망 추정의 문제점을 제시하고, 다중 신경망으로 문제점을 해결함으로서, 조기에 콘크리트 공시체의 압축 강도를 추정하는 시스템(I-PreConS, Intelligent PREdiction system of CONcrete Strength)을 개발하는데 있다.

2. 인공 신경망 모델

콘크리트 강도 추정을 위한 신경망 알고리즘으로는 다변수 비선형 문제에 가장 적합하고 대표적인 오류 역전파 학습 알고리즘(Error Back-propagation Training Algorithm)을 이용하였다. 이 알고리즘을 바탕으로 저자가 기존에 제안한 구조 해석을 위한 신경망 모델 개발 단계³⁾를 기본으로 하여 신경망 모델을 개발하였다.

* 정회원, 현대산업개발 기술연구소, 과장, 공학박사

** 정회원, 현대산업개발 기술연구소, 소장

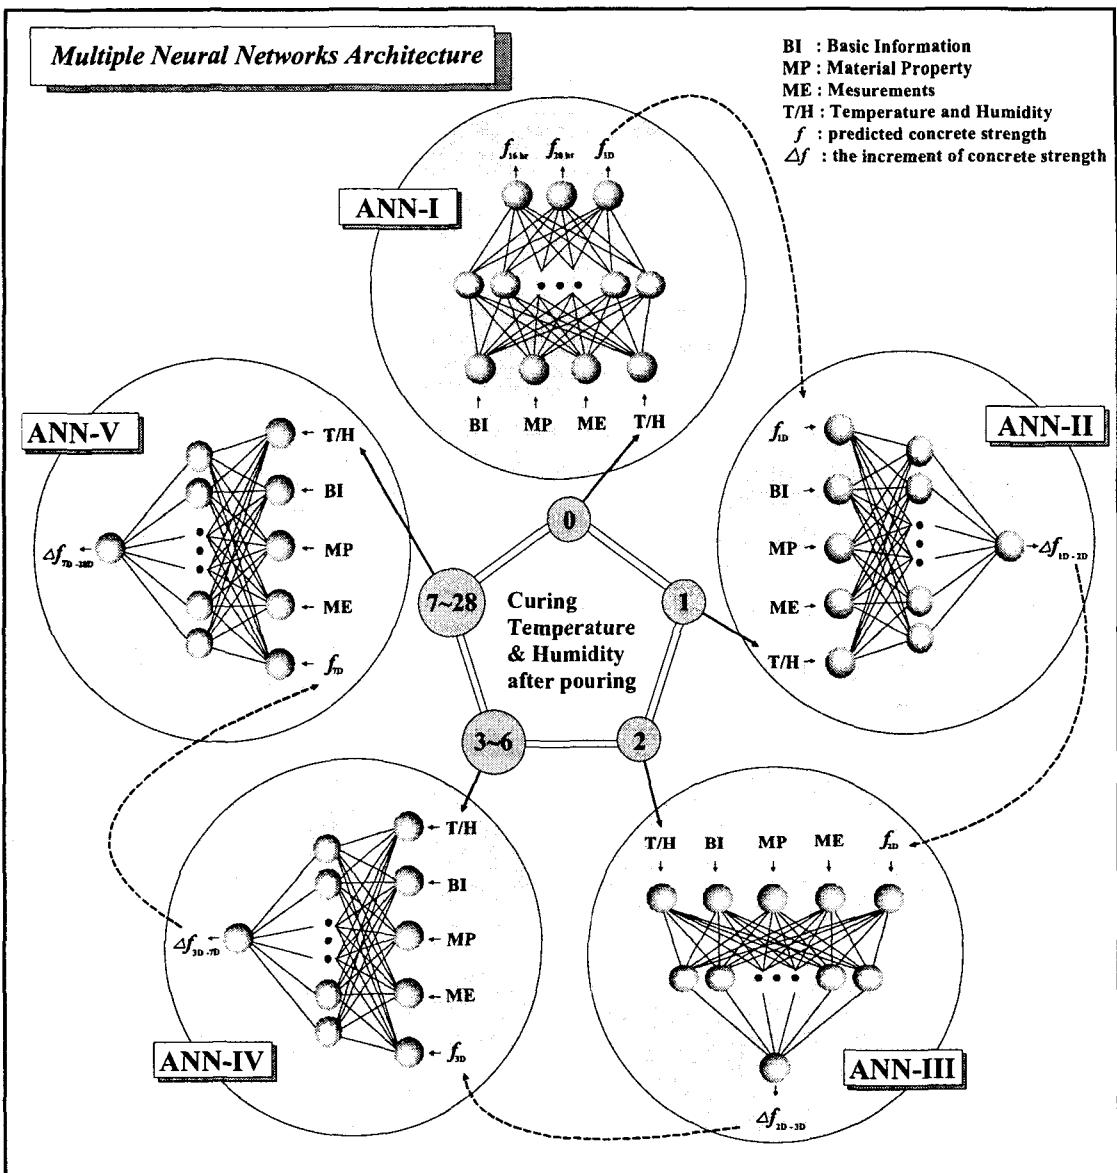


그림 1 다중 신경망 구조

2.1 단일 신경망 추정의 문제점

저자들은 기 발표된 논문¹⁾에서 모든 입력 및 결과 변수를 하나의 신경망 구조에서 고려하는 단일 신경망 구조(참고 문헌¹⁾의 그림 1)를 이용하여 콘크리트 강도를 추정한 바 있다. 참고 문헌¹⁾에서도 나타나듯이 단일 신경망 구조를 적용한 경우에, 학습하지 않은 테스트 패턴으로 테스트한 결과를 시험 결과와 비교시에는 좋은 결과를 보인다. 그러나, 테스트 패턴 중 특정일의 온도만을 증가시켜 입력하였을 경우, 콘크리트 추정 강도가 증가하여야 함에도 불구하고, 추정 강도가 유지 또는 감소되는 경향을 보였다. 이러한 현상이 나타나는 원인은 여러 가지 원인이 복합되어 나타나는 현상일 수 있으나, 근본적인 원인은 모든 입력 변수가 모든 결과에 영향을 미치는 단일 신경망 구조를 사용하였기 때문이다. 즉, 특정일(예, 타설 후 2일)의 온/습도는 실제로 특정일 이후의 강도에만 영향을 줄 수 있지

만, 단일 신경망 구조로는 특정일 이전(예, 타설 후 1일)의 추정 강도에도 영향을 줄 수 있기 때문에 문제점이 발생한다.

2.2 다중 신경망 구조

단일 신경망 추정의 문제점을 해결하고자, 신경망을 분할하여 결과를 도출하는 다중 신경망 구조를 적용하였다. 양생일 대기 온/습도와 양생 시간별(7재령) 콘크리트 강도와의 관계로부터 그림 1과 같이 5개의 분리된 신경망 구조로서 다중 신경망 구조를 구성하였다. 즉, ANN-I 구조에서는 타설 일 평균 온/습도만이 타설 후 1일 강도($f_{16hr}/f_{20hr}/f_{1D}$) 추정과 관련되며, ANN-II/III 구조에서는 타설 후 1일/2일의 평균 온/습도만이 타설 후 2일/3일 강도의 증가치($\Delta f_{1D-2D}, \Delta f_{2D-3D}$) 추정과 관련되도록 하였다. ANN-IV와 ANN-V는 타설 후 3일~6일/7일~28일의 평균 온/습도가 각각 타설 후 7일/28일 강도($\Delta f_{3D-7D}, \Delta f_{7D-28D}$)의 증가치 추정과 관련되도록 하였다. 또한, 5개의 신경망들이 연관성을 가지도록, 전단계의 신경망 추정 강도가 다음 단계 신경망에 입력으로 영향을 주도록 하였다. 즉, 전단계의 신경망(ANN-I)의 추정 강도(f_{1D})가 다음 단계의 신경망(ANN-II)에 입력됨으로서, 강도 증가치(Δf_{1D-2D}) 추정 시에 기준이 될 수 있다.

3. 신경망 모델 개발 단계

단일 신경망과 다중 신경망(ANN-I~V)의 개별 신경망(학습) 모델의 개발 과정은 기 발표된 논문¹⁾과 동일하며 다음에 요약하였다.

3.1 입력층 뉴런수 결정(단계 1)

그림 1과 같이 크게 4가지[기본 정보(BI), 재료 배합(MP), 측정 항목(ME), 대기 온/습도(T/H)]로 분류하여, 기본 정보 3개(타설 시점은 온/습도 조건으로 대체, 타설 지역은 동일하므로 제외), 재료 배합 9개, 측정 항목 3개, 대기 온/습도 58개(타설일부터 타설 후 28일까지)로 총 73개의 변수를 입력 뉴런의 대상으로 하였고, 각 개별 모델마다 다르게 결정하였다.

3.2 출력층 뉴런 수 결정(단계 2)

본 시스템에서 추정하고자 하는 콘크리트 강도는 재령에 따라 증가한다. 초기 재령(타설 후 3일 이내)을 중심으로 7 재령(16시간/20시간/24시간/2일/3일/7일/28일)을 대상으로 하였고, 2.2절에서 설명한 바와 같이 각 개별 모델마다 다르게 결정하였다.

3.3 학습 패턴 생성(단계 3)

학습 패턴 생성을 위해서 공시체 제작 및 압축강도 시험을 수행(참고 문헌¹⁾의 표 1)하였다.

3.4 신경망 변수 결정(단계 4)

학습패턴을 0.9 이하가 되도록 스케일링 하였으며, 최대 허용 에러(Emax)는 저자가 기존에 제안한 규칙^{3,4)}으로부터 결정하였다. 그림 1과 같이 각 신경망 모델에서 은닉층의 수는 1로, 은닉층 뉴런 수는 입력과 출력층 뉴런 수의 합을 최소값으로 초기 가정하였다.

3.5 학습 완료 및 테스트(단계 5)

4. 시뮬레이션 결과 및 분석

본 논문에서는 입력 공간을 분할하여 문제를 해결하고자 하는 다중 신경망에 의한 접근방법을 사용하였다. 다중 신경망²⁾ 구조의 추정 경향을 일반화(generalization)하고 추정도를 항상시키기 위해서는 개별 모델(ANN-I~V)의 최적 구조를 찾아서 적용하여야 한다. 신경망 모델의 최적 구조를 찾기 위해서 유전자 알고리즘을 이용하는 방법²⁾ 등이 있다. 그러나, 본 논문의 주 목적이 최적 구조를 자동으로 찾고자 하는 것이 아니라, 콘크리트 강도의 추정이라는 실용적인 문제를 해결하고자 하는 것 이므로, 기존 콘크리트 강도 추정에 관련한 이론과 경험을 전제로 다음과 같이 다양한 시뮬레이션을 수행하여 결과를 분석·평가함으로서, 개별 신경망 모델의 최적 구조를 결정하고 개별 모델 사이의 연관성을 보였다.

4.1 테스트 패턴

다중 신경망 모델의 추정도를 평가하기 위하여 단일 신경망 모델 개발에서와 동일하게 4개의 테스트 패턴(참고 문헌¹⁾의 표2)으로 평가하였다. 테스트 패턴은 학습에 사용하지 않은 시험 결과값

으로서 tp1과 tp2는 보통 강도(210, 240), tp3와 tp4는 고강도(500, 350)를 선택하였다.

4.2 ANN-I의 시뮬레이션 결과

신경망의 구조를 간단히 표현하기 위하여 ANN(입력층 뉴런 수: 출력층 뉴런 수)와 같은 표시 기호를 사용하였다. 즉, ANN-I은 그림 1과 같이 총 17개의 입력층 뉴런(3-BI, 9-MP, 3-ME, 2-T/H)과 3개의 출력층 뉴런을 가지는 ANN(17:3)의 기본 구조로 표현할 수 있다. 이러한 기본 구조에 가중 및 응축 기법¹¹⁾을 적용하여, 추정도와 추정 경향이 가장 좋은 최적의 구조를 구하고자 하였다. 우선, 가중기법을 적용하여, 물시멘트비에 의해 압축 강도가 상당히 좌우되므로, 설계 기준 강도(fc) 및 물(W)과 시멘트(C) 단위중량에 가중한 경우(Case A), 양생 온도에 따라 압축강도가 상당히 좌우되므로 양생 온도(T)에 가중한 경우(Case B), 양생 온/습도(T/H)에 가중한 경우(Case C)로 구분하였다. 또한, 슬럼프 값·공기량·굳지 않은 콘크리트 온도 등 측정값은 추정시 오차가 상당히 큰 것으로 간주되어, 변수 응축 기법을 적용한 경우(Case E)이다. 가중 뉴런 수는 1개/3개/6개로 증가하며 시뮬레이션 하였다.

시뮬레이션 결과는 표1과 같으며, 추정 결과는 추정의 정확도(Ac)와 경향(Tr)을 비교하였다. 즉, 정확도(Ac)는 4.1절에서 설명한 4개의 테스트 패턴에 대한 평균 퍼센트 에러를 의미하며, 추정 경향은 양생 온도 증가시 추정 강도가 감소·유지·증가하는 가를 판단하였다. 시뮬레이션 결과로부터 가중기법을 단일 적용하였을 경우, 가중 뉴런 수가 증가함에 따라 추정도의 증가는 없으나, 추정 경향이 약간 좋아졌다. 또한, 응축 기법을 단일 적용하였을 경우, 추정도와 추정 경향이 모두 향상됨으로써 측정값의 추정 오차가 상당히 있었음을 알 수 있다.

그러나, 이와 같이 가중·응축 기법을 단일 적용하였을 경우, 추정 경향이 모두 적절하지 못한 것으로 나타나므로 가중·응축 기법을 복합하여 적용하였다. 시뮬레이션 결과는 표2와 같으며, 표1의 Case A에 해당하는 뉴런에 3개의 뉴런으로 가중하고, Case B에 해당하는 뉴런에 6개 뉴런으로 가중하고, Case E에 해당하는 뉴런을 응축한 경우(Case A3B6E), 즉, ANN(29:3) 구조로 가장 좋은 추정도 및 추정 경향을 보였다. 따라서, 이 구조를 ANN-I의 최적 구조로 결정하였다.

4.3 ANN-II/III의 시뮬레이션 결과

그림 1과 같은 다중 신경망 구조에서 ANN-II와 ANN-III는 입출력 구조가 동일하므로 동일한 최적구조를 가진다. ANN-I과 비교해 보면, 전 단계의 신경망(ANN-I)이 추정한 강도가 현재의 신경망(ANN-II)의 입력층에 새로운 입력 변수로 사용되는 것이 다른점이다. 즉, ANN(18:1)이라는 기본 구조를 가진다. 새로운 입력 변수(D, 추정시 입력 기준 강도)의 영향을 보기 위하여, ANN-I의 최적 구조를 기본으로 하고, 가중 및 응축기법을 Case D에 적용하였다. 적용 결과는 표 3과 같으며, 추정시 입력 기준 강도로 가중·응축 기법 없이 하나의 뉴런을 적용하는 것이 가장 적당함을 알 수 있다. 따라서, ANN-II/III도 ANN-I와 같이 Case A3B6E, 즉, ANN(30:1)인 구조를 최적 구조로 결정하였다.

4.4 ANN-IV/V의 시뮬레이션 결과

이전의 신경망들(ANN-I~III)과 비교해 보면, 그림 1과 같이 이전 신경망에서는 1일의 온/습도만을 입력 변수로 고려하지만, ANN-IV/V는 4일/22일간의 평균 온/습도를 고려한다는 것이 크게 다른 점이다. 즉, ANN-IV(24:1)와 ANN-V(60:1)라는 기본 구조를 가진다. 이전 신경망과의 다른점을 고려하기 위하여 양생 온/습도에 가중 기법을 적용하여 시뮬레이션 하였다. 타설 후 3일까지의 압축강도는 강제 양생에 의한 압축강도 추정 경향이 중요하지만, 7일/28일 강도 추정에서는 양생 온도 증가에 따른 추정 경향이 중요하지 않으므로, 추정 결과 비교시 추정도만을 평가하였다. 적용 결과는 표 4와 같으며, 다른 신경망과 동일하게 Case A3B6E인 경우에 가장 좋은 추정도를 보였다. 따라서, ANN-IV(54:1) 및 ANN-V(198:1)인 구조를 최적 구조로 결정하였다.

4.5 단일 및 다중 신경망에 의한 추정 결과 비교

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 설명 할 수 있음을 의미한다. 4절에서 설명한 최적 구조를 가지며, 그림 1와 같은 다중 신경망 모델로 4.1절의 테스트 패턴을 테스트하였다. 다중 신경망 모델의 추정 결과는 그림 2 및 표5와

같다. 참조 논문¹¹⁾의 단일 신경망 모델의 추정 결과(평가 지수 3.72)와 비교하여, 추정도 평가 지수는 3.76으로 유사한 추정도를 보였고, 평균 결정 계수는 모든 테스트 패턴에서 0.9 이상의 상당히 좋은 결과를 보였다. 그러므로, 다중 신경망 모델은 단일 신경망 모델과 유사한 추정도를 보이면서도, 2.2.절에서 설명한 단일 신경망 모델의 문제점을 해결할 수 있다.

5. 결 론

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

- (1) 콘크리트 강도 추정용 인공 신경망 모델 개발시, 단일 신경망 구조에서 발생할 수 있는 추정상의 오류를 다중 신경망 구조로 대체함으로서 해결하였다.
- (2) 다양한 시뮬레이션 결과를 바탕으로, 다중 신경망 구조에서 개별 신경망의 최적 구조를 결정하였고, 개별 모델 사이의 연관성을 보였다. 즉, A3B6E 구조가 다섯개의 개별 신경망의 최적 구조로 나타났다.
- (3) 신경망 모델 개발시 추정도와 추정 경향을 향상시키기 위해서는 가중 및 응축 기법을 적용하는 것이 매우 효과적이다.

감사의 글

콘크리트 공시체 제작에 있어서 협조를 해 주신 아주 레미콘 경기도 광주 공장 품질관리실에 감사드립니다.

참고문헌

1. 이승창, 안정찬, 정문영, 임재홍, “인공신경망을 이용한 콘크리트 강도 추정,” 한국콘크리트학회 봄 학술발표회 논문집, 제14권 1호, 2002.5, pp.997-1002.
2. Happel B.L.M., Murre J.M.J., “The design and evolution of modular neural network architectures,” Neural Networks, 1994. 7, pp.985-1004.
3. 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.
4. Lee S.C., Han S.W., “Neural-network-based models for generating artificial earthquakes and response spectra,” Computers & Structures, 2002;80(20-21), pp.1627-1638.

표 1 가중·응축 기법을 단일 적용한 ANN-I의 시뮬레이션 결과

No. of Weighting neurons	Weighting						Condensation	
	Case A		Case B		Case C		Case E	
	Ac	Tr	Ac	Tr	Ac	Tr	Ac	Tr
0	23.1	×	23.1	×	23.1	×		
1	27.5	×	23.4	△	24.7	△		
3	22.9	△	26.0	△	26.9	△		
6	26.5	△	23.1	△	26.7	△		

Case A : 설계 기준 강도(fc), 물(W)과 시멘트(C)의 단위 중량을 가중하는 경우
Case B : 양생일 평균 온도(T)를 가중하는 경우
Case C : 양생일 평균 온도(T)와 평균 습도(H)를 가중하는 경우
Case E : 측정 항목(ME)의 뉴런을 응축한 경우
Ac: 정확도 (4개의 테스트 패턴에 대한 평균 퍼센트 에러)
Tr : 추정 경향(Trend)
×/△/○: 양생 온도 증가시, 추정 강도가 감소(×), 유지(△), 증가(○)하는 경우

표 2 가중·응축 기법을 복합 적용한 ANN-I의 시뮬레이션 결과

구분	Weighting + Condensation								
	A3E	B3E	C3E	B6E	B9E	A3B3E	A6B6E	A3B6E	A6B3E
Ac	42.9	19.9	32.6	14.9	26.1	15.4	15.3	17.2	26.4
Tr	△	○	○	○	○	○	○	◎	○

A3B6E: 표 1에서 A에 해당하는 뉴런에 3개의 뉴런으로 가중(A3)하고, B에 해당하는 뉴런에 6개의 뉴런으로 가중(B6)하고, E에 해당하는 뉴런을 응축하는 경우
 Ac, Tr, ×/△/○: 표 1과 동일
 ◎: 양생 온도 증가시, 추정 강도가 가장 적절히 증가하는 경우

표 3 가중·응축 기법을 적용한 ANN-II의 시뮬레이션 결과

구분	A3B6E	Condensation	Weighting	
		Case D	A3B6ED2	A3B6ED3
Accuracy	17.2	33.4	25.8	23.0
Trend	◎	×	×	×

Case D: 전 단계의 신경망(ANN-I)이 추정한 강도로서 현재의 신경망(ANN-II)에 입력되며, 추정 시 기준이 되는 추정 기준 강도가 응축되는 경우
 D2: 입력 기준 강도에 해당하는 뉴런에 2개의 뉴런으로 가중한 경우
 ×/△/○/◎: 표 1 및 2와 동일

표 4 ANN-IV와 ANN-V의 정확도 평가

구분	기본 구조	A3B3E	A3B6E	A3B6ED3
ANN-IV	18.1	19.1	13.8	17.2
ANN-V	17.3	12.7	10.1	16.2

정확도: 표 1과 동일

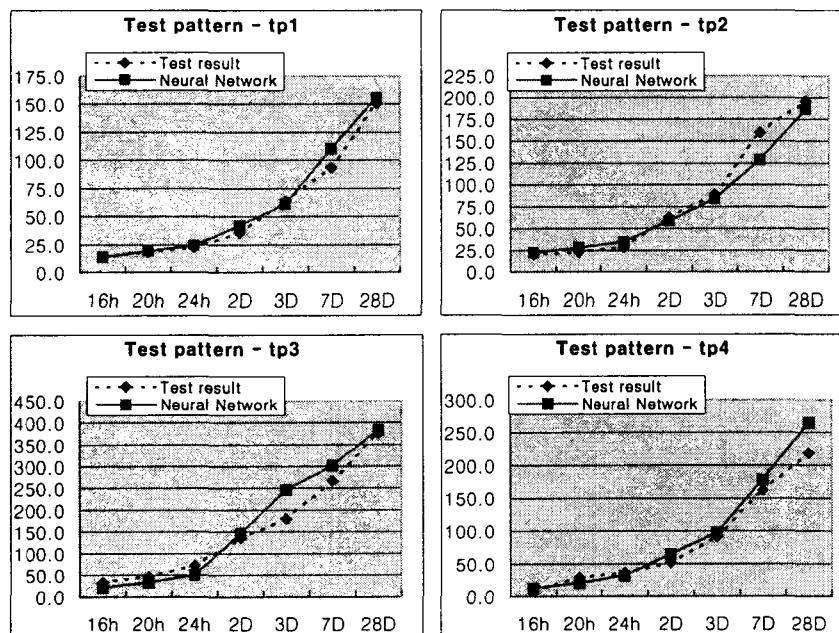


그림 2 다중 신경망 모델의 추정 결과

표 5. 다중 신경망 모델의 추정도 평가

	1차 시도	2차 시도	3차 시도	평균 결정 계수
tp1	0.98	0.97	0.98	0.97
tp2	0.96	0.97	0.96	0.96
tp3	0.93	0.91	0.92	0.92
tp4	0.92	0.90	0.91	0.91

*추정도 평가 지수 : 3.76

*평가지수: 테스트 패턴별 평균 결정계수의 총합