

인공 지진 생성에서 Fourier 진폭 스펙트럼과 변수 추정을 위한 신경망 모델의 개발

Development of Neural-Networks-based Model for the Fourier Amplitude Spectrum and Parameter Identification in the Generation of an Artificial Earthquake

조 빈 아* 이 승 창** 한 상 환*** 이 병 해***
Cho, Bin-Ah Lee, Seung-Chang Han, Sang-Whan Lee, Byung-Hai

ABSTRACT

One of the most important roles in the nonlinear dynamic structural analysis is to select a proper ground excitation, which dominates the response of a structure. Because of the lack of recorded accelerograms in Korea, a stochastic model of ground excitation with various dynamic properties rather than recorded accelerograms is necessarily required. If all information is not available at site, the information from other sites with similar features can be used by the procedure of seismic hazard analysis. Eliopoulos and Wen identified the parameters of the ground motion model by the empirical relations or expressions developed by Trifunac and Lee.

Because the relations used in the parameter identification are largely empirical, it is required to apply the artificial neural networks instead of the empirical model. Additionally, neural networks have the advantage of the empirical model that it can continuously re-train the new recorded data, so that it can adapt to the change of the enormous data.

Based on the redefined traditional processes, three neural-networks-based models (FAS_NN, PSD_NN and INT_NN) are proposed to individually substitute the Fourier amplitude spectrum, the parameter identification of power spectral density function and intensity function. The paper describes the first half of the research for the development of Neural-Networks-based model for the generation of an Artificial earthquake and a Response Spectrum(NNARS).

keywords : artificial neural networks, empirical model, parameter identification, artificial earthquake

1. 서론

비선형 동적 거동을 나타내는 구조물의 해석에서 무엇보다 중요한 일은 구조물의 반응을 좌우하는 하중 형태를 결정하는 것이다. 특히, 비대칭 구조나 질량 및 강성 분포가 불규칙한 비정형 구조물의 경우, 동적 해석에 의한 내진 설계 시 지진하중의 형태는 설계 결과에 많은 영향을 준다. 이러한 동적 해석법으로는 비교적 간단하게 구조물의 동적 특성을 고려할 수 있는 응답 스펙트럼 해석법과 상당한 시간이 요구되기는 하나 정밀한 동적 해석 결과를 얻기 위해 지진 가속도 기록을 직접 적분하여 사용하는 시간 이력 해석법이 있다. 이 두 가지 방법 중 시간 이력 해석법에 의한 해석 결과가 신뢰성을 가지기 위해서는 적절한 지진 기록이 요구된다.

그러나, 국내에서 기록된 지진의 수는 부족할 뿐만 아니라, 기록된 데이터의 수집과 정리가 미흡하므로 국내 특성에 부합되며 기준이 될만한 지진 기록의 제시가 어려운 실정이다. 그러므로, 우리나라와 같이 지진 기록이 부족한 경우에는 실제로 발생한 지진 기록에 의존하기 보다 지진의 여러 가지 동적 특성과 지진 기록이 많은 다른 유사한 지역의 기본적인 정보를 바탕으로 확률론적 지반 운동 모델(stochastic ground motion model)을 개발하여 다양한 인공 지진파를 발생하여야 한다.

지진은 지진규모, 진앙거리 및 지질학적 변수 등에 따라 불규칙하게 발생되어 불확실하고 불확정적인 특성을 내포하기 때문에 기존의 인공 지진파 발생에 관련된 연구¹⁾²⁾³⁾에서는 확률론적이거나 경험

* 한양대학교 건축공학과 석사과정
** 한양대학교 초대형구조시스템연구센터 연구조교수
*** 한양대학교 건축공학과 교수

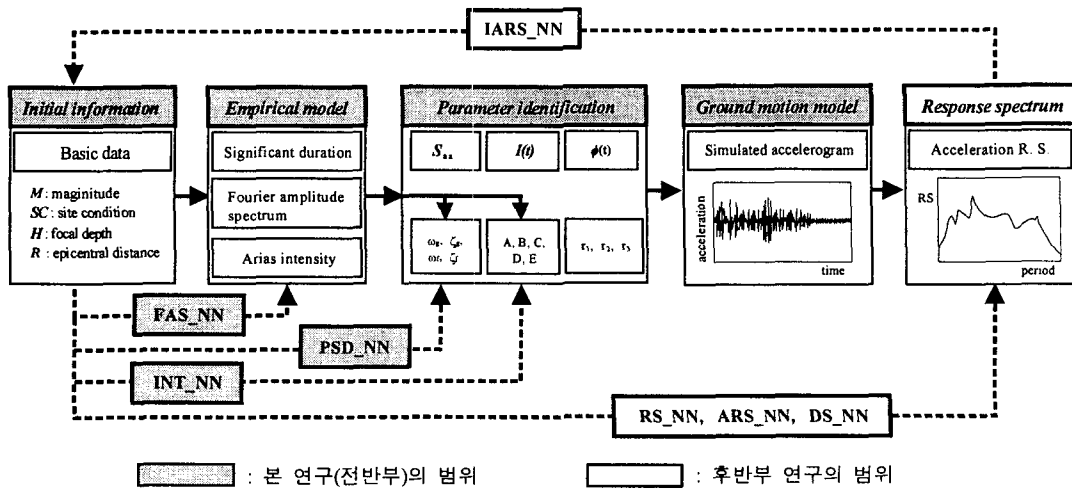


그림 1 인공 지진 생성과 관련한 기존 과정의 분석 및 신경망 모델

적인 과정을 포함하고 있다. 1990 년대에 들어서며 소프트 컴퓨팅(soft computing)¹⁾ 분야로 대표되는 인공 신경 회로망(이하, 신경망)은 불확실성을 내재한 부정확한 정보를 다루는데 있어 그 효율성이 뛰어나기 때문에 구조공학의 많은 분야에 적용되고 있다. 그러므로, 인공 지진파를 생성하는 과정 중에서 경험적이고 확률론적인 분포를 다루는 부분에 신경망을 도입할 필요가 있다. 인공 지진파 생성과 관련한 신경망 적용 연구는 최근 Ghaboussi⁵⁾ 등에 의해 진행되고 있으며, 신경망은 기존의 경험적인 모델에 비해서 새로운 데이터를 계속적으로 재학습할 수 있는 장점을 가지고 있다.

본 연구는 인공 지진파와 응답 스펙트럼을 생성하기 위한 신경망 모델 (NNARS: Neural-Networks-based model for the generation of an Artificial earthquake and a Response Spectrum)을 개발하고자 수행한 연구의 전반부로서, 기본적인 정보로부터 신경망을 이용하여 인공 지진파를 발생하는데 목적이 있다.

2. NNARS 의 전반부 개발

2.1 NNARS 개발 개념

신경망은 블랙 박스(black box)⁶⁾로 간주될 정도로 내부적인 프로세스가 명확히 나타나지 않는 특성을 가지고 있다. 즉, 입력과 출력 데이터의 매핑(mapping)에 의해 학습이 이루어지는 감독 학습(supervised learning) 알고리즘⁷⁾을 사용할 경우, 그 중간 단계 또는 내부의 자세한 단계가 반드시 필요하지 않기 때문에 신경망을 이용한다면 몇 단계를 뛰어넘을 수 있다. 기존의 전통적인 프로세스를 정확히 분석한 후, 이와 같은 특성을 이용하여 한 단계씩 신경망 모델로 대체하고, 시뮬레이션 결과를 평가함으로써 유용한 신경망 모델을 개발할 수 있을 것으로 예상된다.

본 연구에서는 이러한 개념을 적용하기 위해서 다변수(多變數) 문제에 적합한 오류 역전파 학습 알고리즘(error backpropagation training algorithm)⁷⁾을 바탕으로 하여 본 연구자⁸⁾(1997)가 제안한 개발 단계⁸⁾를 사용하여 인공 지진파 생성과 관련한 총 3 개의 신경망 모델을 개발하였다.

2.2 기존 과정 분석

본 연구에서는 기존 연구^{1) 2) 3)}로부터 그림 1 과 같이 인공 지진 생성과 관련한 과정을 크게 다섯 부분으로 분류하고, 연구의 범위를 초기 정보에서부터 지반 운동 모델까지 한정하여, 다음과 같이 재정의하였다. Trifunac³⁾은 지진 자체의 특성인 규모(M)와 지역적인 특성인 지반조건(SC), 진앙깊이(H), 진앙거리(R)를 기본 정보로 하여, 유효 지반 운동 시간(significant duration, t_b)과 푸리에 진폭 스펙트럼(Fourier amplitude spectrum, FAS)을 생성하는 경험적인 모델을 제안하였다.

Yeh⁴⁾는 지진의 부정형(nonstationary)한 특성을 고려하기 위해서, 실제 지진 기록을 기반으로 지반 운동 모델을 강도함수(intensity function, INT) $I(t)$, 파워 스펙트럼 밀도함수(power spectral density function, PSD) S_{aa} , 주기 변조 함수(frequency modulation function) $\phi(t)$ 의 3 개의 함수로 구성하고, 식(1)과 같은 형태로 인공 지진파 $a(t)$ 를 발생하였다.

$$a(t) = I(t) \bar{\zeta}(\phi(t)) = I(t) \zeta(t) \quad (1)$$

여기서, $\bar{\zeta}(\phi(t))$ 는 $\phi(t)$ 에 대한 여과된 백색파(filtered white noise)이다. 또한, Eliopoulos⁵⁾는 지진의 형태를 특징적(characteristic) 지진과 비특징적(non-characteristic) 지진으로 분류하고, Trifunac의 경험 모델을 이용하여 3개 함수의 변수를 추정하였다. 즉, 푸리에 진폭 스펙트럼과 이로부터 구한 Arias intensity⁶⁾를 기반으로 강도함수와 파워 스펙트럼 밀도함수의 변수를 추정하였고, 주기 변조 함수의 변수는 지역적인 특성을 나타내므로 해당 지역에서 기록된 평균값과 총 지반운동 시간(t_f)으로부터 추정하였다.

2.3 NNARS의 단위 모델

그림 1과 같이 경험적인 모델 단계에서는 초기 정보로부터 푸리에 진폭 스펙트럼을 구하는 FAS_NN을 개발하였고, 변수 추정 단계에서는 기록된 지진 기록의 평균값을 필요로 하는 $\phi(t)$ 를 제외한 S_{aa} 와 $I(t)$ 의 변수를 추정하는 PSD_NN, INT_NN을 개발하였다. 지반 운동 모델 단계에서, 4개의 초기 정보와 수천 개의 지진 가속도 기록을 매핑한다는 것은 데이터의 수가 과도해질 뿐만 아니라, 전 단계의 변수를 추정하면 이 단계는 방정식을 푸는 과정이므로 신경망을 적용하여 기존 방법보다 높은 정확도를 확보하기는 어려울 것으로 思料되어 신경망 모델 생성에서 제외하였다.

3. 인공 지진파 생성을 위한 신경망 모델

3.1 신경망을 이용한 푸리에 진폭 스펙트럼 모델 (FAS_NN)

지진 가속도의 푸리에 스펙트럼은 시계영역(time domain)의 지진파를 주파수영역(frequency domain)으로 변환시켜 각 성분파의 분포를 나타낸 것으로, 본 연구에서는 Trifunac³⁾이 제안한 경험 모델 중에서 단층 주변에서 지진이 일어난다고 가정하는 특징적 지진에 한정하여 FAS_NN을 개발하였다.

푸리에 진폭 스펙트럼 모델은 식(2)와 같이 지진규모(M), 지반조건(SC), 주파수 감쇠함수(Att(Δ, M, T))의 항으로 구성되며, 감쇠함수의 Δ 는 진앙거리(R)와 진앙깊이(H)에 의해 재정의된다. 여기서, b_1, b_2, b_3, b_6 는 주기(T)에 따른 회귀분석 계수로 표³⁾에 의해 결정되며, ϵ_s 는 각 항의 불확실성을 고려한 정규분포 에러항이다. 또한, 유효 지반운동 시간 t_b 는 식(3)과 같이 지진규모, 진앙거리, 정규분포 에러항 ϵ_D 로 산정한다.

$$\log_{10} FS(T) = M + Att(\Delta, M, T) + \dot{b}_1(T)M + \dot{b}_2(T)SC + \dot{b}_3(T) + \dot{b}_6(T)M^2 - \epsilon_s \quad (2)$$

$$\log_{10} t_b = -0.14 + 0.2 M + 0.002 R + \epsilon_D \quad (3)$$

본 연구에서는 신경망 모델의 개발을 위해 본 연구자⁷⁾(1997)⁸⁾가 제안한 개발 단계를 기본으로 하여 학습 패턴 선정, 신경망 구조, 학습 방법 등을 다음과 같이 결정하였다. 학습 패턴의 수렴성과 정확성 보장을 위해 학습 변수의 범위를 M은 6.0~8.0, SC는 0, 1, 2 (단, SC의 값은 암반은 2, 충적층은 0, 충적층과 암반의 중간 지역은 1), H는 1~30m, R은 30~50m로 한정된 후, Hypercube 방법¹⁰⁾에 의해 25개($2^3 + 2 \times 4 + 1$)의 학습 패턴의 입력값을 생성하고, 前述한 경험 모델식을 이용하여 선정한 학습 패턴마다 주기 범위

표 3.1 FAS_NN의 학습 패턴

pattern No.	input value				desired output value				
	M(mag.)	SC	H(m)	R(m)	FAS(1)	FAS(2)	FAS(3)	...	FAS(12)
p1	8.0	2	1	50	0.0990778	0.6301735	2.9283642	...	4.9310342
p2	8.0	2	30	50	0.0760716	0.5044897	2.4372218	...	4.9446857
p3	6.0	0	30	50	0.0165111	0.1463908	0.863686	...	2.2314484
~				
p25	7.0	1	30	40	0.0506841	0.3905988	2.0928289	...	3.0499409

0.04~14 초 내를 12 구간으로 나누어 퓨리에 진폭 스펙트럼에 해당하는 기대값(desired output)을 결정하였다.

$$E_{max} < 0.5 \times (\text{학습패턴의 기대값 중 최소값})^2 \times \text{출력 층 뉴런수} \quad (4)$$

$$E_{max} < \{ 0.5 \times (0.0698474)^2 \times 12 = 2.927e^{-2} \}$$

학습의 최대 허용 에러는 본 연구자*(1997)⁹⁾가 제안한 최대 허용 에러 산정식인 식(4)를 적용하여, $E_{max} = 2.0e^{-2}$ 로 초기 가정 하였으며, 그림 3.1 과 같이 은닉층의 수는 1로, 은닉층 뉴런수는 입력층과 출력층 뉴런수의 합인 16 개로 초기 가정하였다. 활성화함수는 경사도 계수 1.0 의 시그모이드(unipolar sigmoid) 함수를 사용하였고, 학습 상수와 모멘텀 항은 각각 0.5, 0.8 로 결정하여 학습을 수행하였다.

학습은 2018 회($E_{max}=2e^{-2}$ 의 경우) 만에 완료되었으며, 최대 허용 에러 산정식의 적합성 여부를 판단하기 위해 초기 가정값($2e^{-2}$)보다 적은 값($5e^{-4}$, $5e^{-6}$)으로 최대 허용 에러를 결정하여 시뮬레이션을 수행하였다. 학습 완료 후 학습 범위내에서 표 3.2 와 같이 임의적으로 4 개의 패턴을 선정하여 테스트 하였다. FAS 가 12 개의 데이터에 의해 이루어지고, 각 데이터에 대한 에러보다는 전반적인 에러가 중요하므로 에러의 총합을 테스트 에러로 하였다.

테스트 패턴과 최대 허용 에러에 따른 테스트 결과는 표 3.2 와 같으며, 최대 에러 산정식에 의해 초기 가정된 값($E_{max}=2e^{-2}$)으로 충분히 학습이 이루어졌음을 알 수 있다. 즉, 두 번째 테스트 패턴(tp2)의 테스트 결과를 볼 때 이를 확인할 수 있으며, 최대 허용 에러가 감소함에 따라 테스트 에러가 감소하기도 하고 증가하기도 하는 현상은 초기 연결 강도 값이 랜덤하게 결정되었기 때문에 나타나는 것으로 최대 허용 에러가 감소했기 때문에 나타나는 현상은 아니다. 또한, 초기 연결 강도 값이 랜덤




그림 3.1 FAS_NN 의 신경망 구조

표 3.2 FAS_NN 의 테스트 패턴과 최대 허용 에러에 따른 테스트 결과

pattern No.	input value				Error (%)		
	M (mag.)	SC	H(m)	R(m)	$E_{max} = 2e^{-2}$	$E_{max} = 5e^{-4}$	$E_{max} = 5e^{-6}$
tp1	7.5	0	22	45	34.188	17.595	20.222
tp2	7.5	1	22	35	12.865	19.381	13.850
tp3	7.5	2	8	45	39.419	25.545	28.531
tp4	6.5	0	8	35	39.232	19.138	16.848

Note: Error 는 FAS(1)-FAS(12)의 각 Error 의 총합임.

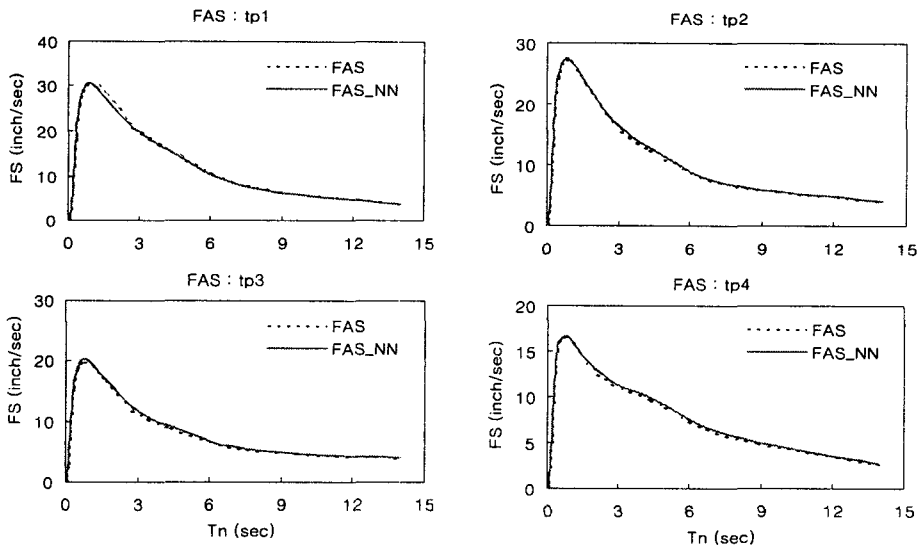


그림 3.2 FAS_NN 의 테스트 결과

하게 결정되었으므로 반복 회수의 비교는 무의미하여 비교 대상에서 제외하였다.

최대 허용 에러를 $E_{max}=2e-2$ 로 하였을 때, FAS_NN의 테스트 결과는 그림 3.2와 같다. 4개의 테스트 패턴 모두 최대 에러 10% 이내의 상당히 좋은 결과를 보이고 있다.

3.2 신경망을 이용한 파워 스펙트럼 밀도함수 모델 (PSD_NN)

푸리에 스펙트럼의 종축을 강조한 파워 스펙트럼은 정형법(stationary process)의 경우, 지반 운동의 총 시간 t_f 를 고려하여 식(5)와 같이 푸리에 스펙트럼의 자승 형태로 나타낼 수 있다. 또한, 부정형의 경우에도 이 식을 이용하여 $FS^2(\omega)$ 로부터 식(6)과 같은 Clough-Penzien 스펙트럼¹¹⁾의 매개변수 $\omega_g, \zeta_g, \omega_f, \zeta_f$ 를 추정할 수 있다. 표 3.3과 같이 前述한 모델과 동일하게 25개 패턴의 입력값을 생성하였고, 비선형 회귀분석 방법인 Newton-Raphson¹²⁾법을 이용하여 각 패턴의 기대값인 매개변수 값을 결정하였다.

$$S_{aa}(\omega) = \frac{1}{\pi t_f} FS^2(\omega) \quad (5) \quad S_{CP}(\omega) = S_0 \left[\frac{\omega_g^4 + 4\zeta_g^2 \omega_g^2 \omega^2}{(\omega_g^2 - \omega^2)^2 + 4\zeta_g^2 \omega_g^2 \omega^2} \right] \left[\frac{\omega^4}{(\omega_f^2 - \omega^2)^2 + 4\zeta_f^2 \omega_f^2 \omega^2} \right] \quad (6)$$

그림 3.3과 같이 은닉층 수는 1로, 은닉 층 뉴런수는 8로 신경망 구조를 초기 가정하였고, $E_{max} < \{ 0.5 \times (0.0234862)^2 \times 4 = 1.103e^{-3} \}$

상기와 같이 최대 허용 에러를 산정하여 학습을 수행하였으며, 학습 완료 후, 前述한 모델과 동일한 패턴으로 테스트 하였다. PSD_NN의 수치적인 테스트 결과는 표 3.4와 같으며, 테스트 패턴 tp2와 tp3에서 20% 이상의 에러가 발생하고 있음을 알 수 있다.




그림 3.3 PSD_NN의 신경망구조

표 3.3 PSD_NN의 학습 패턴

pattern No.	desired output value			
	ω_g	ζ_g	ω_f	ζ_f
p1	10.9676662	0.6564095	2.2561670	0.6539139
p2	9.4746934	0.7835037	1.8751599	0.7785541
p3	5.0835969	0.5585835	5.2940819	4.7918901
~			...	
p25	10.6402098	0.7712880	0.7302511	1.5070866

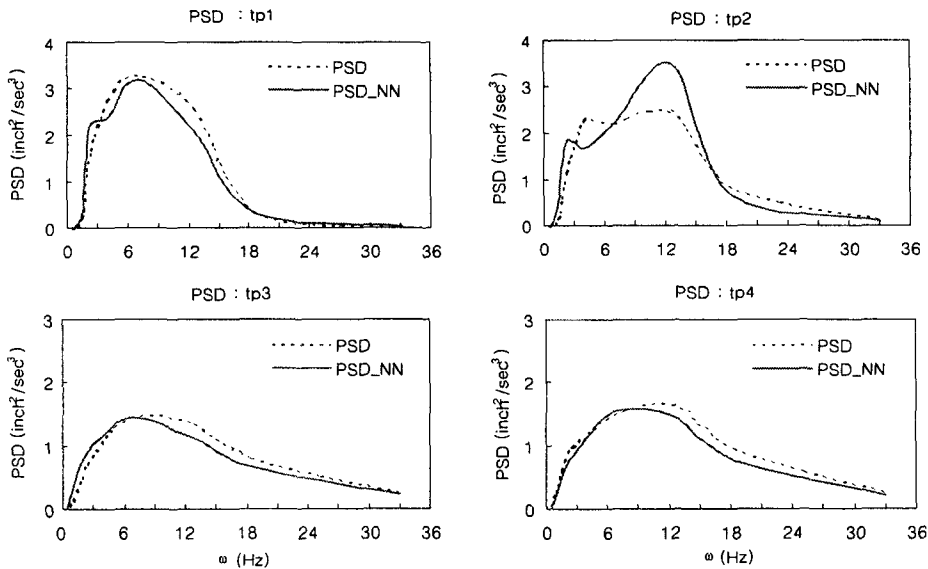


그림 3.4 PSD_NN의 테스트 결과

표 3.4 PSD_NN의 수치적인 테스트 결과

pattern No.	ωg			ζg			ωf			ζf		
	PSD	PSD_NN	Error	PSD	PSD_NN	Error	PSD	PSD_NN	Error	PSD	PSD_NN	Error
tp1	10.457	10.197	2.484	0.259	0.277	-6.927	2.622	2.351	10.332	0.322	0.335	-4.002
tp2	12.222	11.981	1.970	0.426	0.304	28.60	2.672	1.922	28.047	0.368	0.417	-13.27
tp3	11.539	9.970	13.595	0.709	0.811	-14.49	1.648	0.966	41.411	0.830	0.919	-10.73
tp4	12.682	11.419	9.962	0.623	0.629	-0.965	1.137	1.214	-6.762	0.787	0.887	-12.78

Note: Error의 단위는 %임.

Clough-Penzien 스펙트럼의 4개의 변수는 FAS의 12개의 데이터를 가지고 비선형 최소 자승법¹³⁾을 이용하여 구하기 때문에, 결과값 자체의 수치적인 에러보다는 그림상으로 보간하는 경향을 파악할 필요가 있다. 테스트 결과는 그림 3.4와 같으며, 수치적으로 에러가 많이 발생했던 tp3는 그림상으로 상당히 에러가 줄었음을 알 수 있다. 그러나 tp2의 테스트 결과는 계속적으로 많은 에러를 보이기 때문에 PSD_NN이 매개변수 추정기법을 대체하기는 어려울 것으로 판단된다.

3.3 신경망을 이용한 강도함수 모델 (INT_NN)

강도함수는 지진의 에너지함수⁹⁾를 의미하는 시간에 대한 함수로서 식(7)과 같이 지반 가속도 a(t)를 총 지반운동 시간 t_e에 대해 적분하거나 푸리에 진폭 스펙트럼 FS(ω)를 전체 주파수에 대해 적분하는 것으로 정의한다. 또한, Yeh²⁾가 제안한 식(8)과 같은 함수 형태로 표현될 수 있으며, 매개변수 A, B, C, D, E는 비선형 최소 자승법¹²⁾으로 구한다.

$$I_A = \int_0^{t_e} a^2(t) dt = \frac{1}{\pi} \int_0^{\infty} FS^2(\omega) d\omega \quad (7)$$

$$I^2(t) = A \frac{t^B e^{-Ct}}{D + t^E} \quad (8)$$

INT_NN의 학습패턴은 표 3.5와 같이 생성하였으며, 다음과 같이 최대 허용 에러를 3.0e⁻⁶으로 설정하고, 이외는 前述한 모델과 동일한 방법으로 학습을 수행하였다.

$$E_{max} < \{ 0.5 \times (0.0012119)^2 \times 5 = 3.672e^{-6} \}$$

前述한 모델들과 비교하여 상당히 많은 학습 시간(3947267회)이 소요되었고, 비교적 많은 은닉층 뉴런 수(25개)가 필요하였다. 이것은 학습 패턴의 기대값 중 A(7.54013 ~ 2275.80321)와 D(0.23586 ~ 175.15491)의 패턴범위가 넓기 때문이다.

학습 완료 후에는 前述한 모델과 동일한 패턴으로 테스트 하였고, INT_NN의 수치적인 테스트 결과는 표 3.6과 같다. 수치적으로 테스트 패턴 tp2와 tp4의 변수 D에서 20% 이상의 에러가 발생하고 있다.




그림 3.5 INT_NN의 신경망구조

표 3.5 INT_NN의 학습 패턴

pattern No.	desired output value				
	A	B	C	D	E
p1	1055.30776	2.6119980	0.0329014	129.368167	3.2609584
p2	496.000202	2.7680609	0.0477687	82.4024303	3.0691728
p3	14.7316359	4.1259569	0.0717396	0.6368492	3.9073367
~
p25	205.22203	3.0128528	0.0492531	11.427026	3.3739334

표 3.6 INT_NN의 수치적인 테스트 결과

pattern No.	A			B			C			D			E		
	INT	INT_NN	Error	INT	INT_NN	Error	INT	INT_NN	Error	INT	INT_NN	Error	INT	INT_NN	Error
tp1	647.2	559.4	13.56	3.31	3.36	-1.65	0.059	0.063	-6.60	48.43	53.24	-9.93	3.500	3.470	0.88
tp2	639.3	686.8	-7.43	2.95	2.97	-0.63	0.052	0.051	0.69	30.24	39.94	-32.1	3.313	3.333	-0.60
tp3	455.3	495.5	-8.83	2.67	2.67	-0.13	0.039	0.039	-1.25	30.91	34.01	-10.0	3.200	3.212	-0.37
tp4	140.3	132.1	5.87	3.39	3.35	1.22	0.060	0.061	-1.49	2.87	1.73	39.66	3.615	3.573	1.18

Note: Error의 단위는 %임.

그러나, 그림 3.6 과 같이 함수로 표현했을 경우에는 함수에 대한 변수 D의 영향이 적으므로, 모든 패턴이 좋은 결과를 보인다. 따라서, INT_NN은 강도함수의 매개변수 추정기법¹²⁾을 代替 可能할 수 있을 것으로 思料된다.

3.4 인공 지진파의 발생

인공 지진파는 파워 스펙트럼 밀도함수, 강도함수, 주기 변조 함수의 변수값을 기본으로 식(1)에 의해 발생한다. PSD와 INT의 변수는 초기 정보(M, SC, H, R)로부터 구할 수 있으나, 주기 변조 함수의 계수는 특정 지역의 기록된 지진에서 매우 유사하게 나타나므로 평균하여 사용하여야 한다¹⁾.

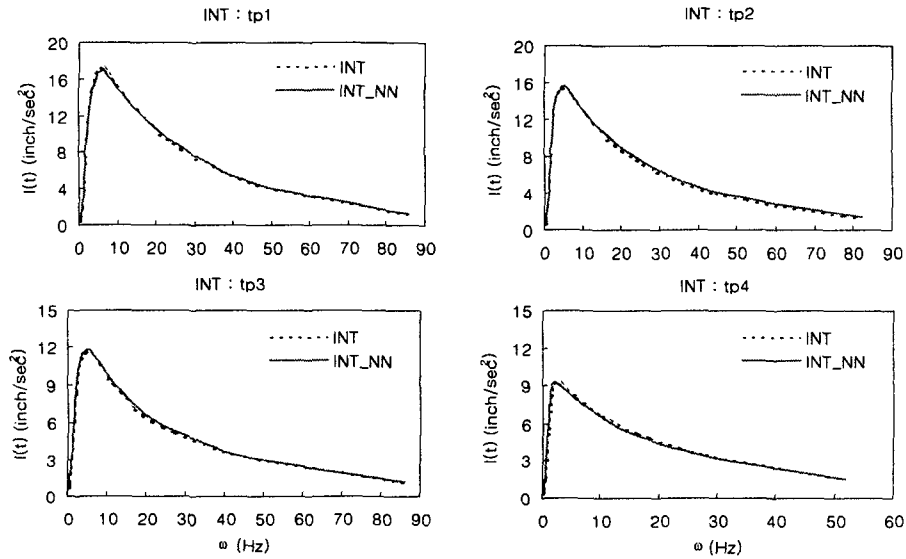


그림 3.6 INT_NN의 테스트 결과




그림 3.7 테스트 패턴에 대한 인공 지진파

국내의 지진 기록이 부족하고 평균값의 제시가 본 연구의 목적은 아니므로, 본 연구에서는 Eliopoulos¹⁾가 사용한 미국 LA 지역의 지진 기록으로부터 구한 주기 변조 함수의 평균값을 사용하였다. 前述한 신경망 모델에 의해 4 개 테스트 패턴의 변수값을 구하고, 이를 바탕으로 그림 3.7 과 같이 인공 지진파를 발생하였다.

4. 결론

본 연구는 인공 지진파를 생성하기 위한 신경망 모델(NNARS의 전반부)을 개발한 것으로, 다음과 같은 결론을 얻었다.

1. 전통적인 프로세스를 한 단계씩 신경망 모델로 代替하고, 시뮬레이션 결과를 분석 평가하여 유용한 신경망 모델을 개발하고자 하는 NNARS의 개발 개념은 본 문제에 대한 적용을 통하여 타당성이 검증되었으며 향후 다른 문제에도 적용할 수 있다.
2. 기존의 경험적인 퓨리에 진폭 스펙트럼 산정식에 해당하는 FAS_NN은 전체적으로 만족스러운 결과를 보였으며, 기존의 경험적인 모델이 새로운 데이터에 적용하기 어려우나 신경망 모델은 새로운 데이터 에도 재학습을 통해 적용할 수 있기 때문에 FAS_NN이 기존 경험 모델을 代替할 수 있을 것으로 思料된다.
3. 비선형 최소 자승법에 해당하는 INT_NN의 테스트 결과는 받아들일 수 있는 수준이었으나, PSD_NN의 테스트 결과는 만족스럽지 못했다. 정확도를 확보하기 위해서는 학습 패턴의 범위를 조정하거나 학습 패턴의 수를 증가시켜야 하기 때문에, 현 상태로는 신경망 모델로 비선형 최소 자승법을 代替하기는 어려울 것으로 思料된다.
4. 신경망 모델에 의해 생성한 인공 지진파는 정밀한 동적해석을 할 수 있는 시간 이력 해석법의 입력 하중으로 사용할 수 있다.
5. 기존에 개발한 신경망 근사 해석 모델 개발 단계^{*)} 중 최대 허용 에러 산정식을 본 문제에 적용하여 학습 後의 정확도를 확보할 수 있었으므로, 식에 대한 타당성이 再次 검증되었다.

감사의 글

본 연구는 한양대 초대형구조시스템연구센터와 건교부 국책 과제 지원에 의한 것으로서 이에 감사드립니다.

참고문헌

1. D. F. Eliopoulos, and Y. K. Wen, *Method of Seismic Reliability Evaluation for Moment Resisting Steel Frames*, Structural Research series No.562, Civil Eng., Urbana-cham., Illinois. 1991, pp. 5~34
2. C. H. Yeh, and Y. K. Wen, "Modeling of non-stationary ground motion and analysis of inelastic structural response," *Structural Safety*, 1990, pp. 281~298
3. M. D. Trifunac, and V. W. Lee, "Empirical Models for Scaling Fourier Amplitude Spectra of Strong Ground Acceleration in Terms of Earthquake Magnitude, Source to Station Distance, Site Intensity and Recording site Conditions," *Soil Dynamics and Earthquake Eng.*, Computational Mechanics Publications, Vol. 8, No. 3, 1989
4. J. -S. Jang, C. -T. Sun, and E. Mizutami, *Neuro-Fuzzy and Soft Computing*, Prentice-Hall, 1997, pp. 1~9
5. J. Ghaboussi, and C. J. Lin, "A New Method of Generating Artificial Earthquake Accelerograms Using Neural Networks," *7th International Conference on Computing in Civil and Building Eng.*, Seoul, Korea, 1997, Vol. 2, pp. 1513~1518
6. J. M. Benitez, J. L. Castro, and I. Requena, "Are Artificial Neural Networks Black Boxes?," *IEEE Transactions on Neural Networks*, Vol.8, No.5, 1997, pp. 1156~1164
7. J. M. Jurada, *Introduction to Artificial Neural Systems*, West Pub. Com., 1992, pp. 163~250
8. 이승창, *신경망을 이용한 스티브 거더 시스템의 근사 해석 모델 개발*, 한양대학교 대학원 박사학위 논문, 1997
9. A. Arias, "A Measure of Earthquake Intensity," *Seismic Design for Nuclear Power Plants*, R. Hensen, Editor. MIT Press, Cambridge, Massachusetts, 1970
10. James L. Rogers, "Simulating Structural Analysis with Neural Network," *Journal of Computing in Civil Engineering*, Vol. 8, No. 2, 1994, pp. 252~265
11. R. W. Clough and J. Penzien, *Dynamics of Structures*, McGraw-Hill Book Com., 1993, pp. 598~611
12. S. C. Chapra and R. P. Canale, *Numerical Methods for Engineers*, McGraw-Hill Book Com., 1990, pp. 355~361