

풍동실험 데이터의 해석을 위한 중요한 기법들



정승환

1. 서 론

최근 하드웨어와 소프트웨어의 발달로 방대한 양의 모형 및 현장 실험 데이터의 획득이 용이하게 되었다. 풍공학 분야에서도 전자적인 압력 측정 시스템의 사용으로 수백 개의 압력 탭에서 측정되는 물체 표면 압력의 긴 기록을 거의 동시에 샘플링할 수 있게 되었다. 풍공학 연구 분야들 중의 하나인 풍동실험에서 이러한 전자장비의 사용은 방대한 양의 데이터 획득을 가능케 하였다. 이와 같이 방대한 양의 데이터에 합유된 풍부한 정보는 전통적인 데이터 해석 기법을 사용하여 해석하기가 어렵다. Karhunen-Loeve 전개로서 알려진 고유직교분해(proper orthogonal decomposition 또는 POD)는 그러한 방대한 데이터의 해석에 적합한 기법이다.

POD는 난류에 관한 연구에서 데이터의 해석과 축소를 위해 처음으로 적용되었다. 풍공학 분야에서 POD는 풍속이나 구조물에 작용하는 풍하중을 분석하기 위해 사용되었다.^{1), 5)} Davenport³⁾는 풍하중과 구조응답의 상호관계에 관한 연구에서 풍하중의 수학적 표현을 단순화시키기 위해 POD를 적용하

였고, Tamura 등⁴⁾은 POD를 사용하여 빌딩에 접근하는 바람과 풍하중 사이의 관계를 밝히고자 하였다. 본 기사에서는 풍동실험을 통하여 구조물 모형의 수백 개의 지점에서 동시에 측정된 풍압력의 해석을 위해 POD가 적용되는 과정이 소개된다.

자기회귀 이동평균(autoregressive moving average 또는 ARMA) 모델은 확률론적인 원리를 사용하여 계산된 유한한 수의 매개 변수들에 의해서 데이터를 나타내는데 이 모델은 풍하중을 근사적으로 모사하기 위하여 사용될 수 있다. ARMA⁽⁶⁾ 모델은 구조물에 접근하는 바람과 바람에 기인한 하중에 대한 옥외 및 실험실에서의 연구를 포함하여 여러 풍공학의 연구분야에서 이용되었는데, 특히 AR 모델은 옥외 실험에서 측정된 냉각탑 표면의 풍압력⁷⁾이나 풍동실험에서 얻어진 건물 지붕 표면의 압력⁸⁾을 모델화하기 위해 사용된 바 있다. 본 기사에서는 구조물 표면에서 측정된 풍압력의 시간적인 특성을 분석하기 위해 ARMA 모델이 적용되는 과정을 소개하고자 한다.

인공 신경망(artificial neural network)은 시계열의 식별(identification)과 예측을 목적으로 한 비매개 변수적 식별 기법이다. 풍공학 분야에서, 반구

* 정희원 · 연세대학교 산업기술연구소 토목연구부, 전문연구원

형의 지붕에 작용하는 평균 풍하중⁽⁹⁾을 예측하거나 인접한 빌딩들이 풍하중에 미치는 간접 효과⁽¹⁰⁾를 연구하기 위해서 신경망이 이용되었다. 또한 바람에 의하여 빌딩에 발생되는 손상을 예측⁽¹¹⁾하기 위해 신경망이 사용되기도 하였다. 본 기사에서는 구조물의 상면에 작용하는 풍압력을 시계열을 근사적으로 모사하기 위해 역전파(backpropagation) 신경망이 적용되는 과정이 소개된다.

2. 이론적 배경

2.1 고유 직교 분해

태풍 또는 토네이도를 많이 받는 미국이나 일본과 같은 지역에서는 주택, 빌딩, 교량 등의 구조물에 바람으로 인한 재산 및 인명 피해가 많이 발생하고 있다. 또한 바람의 영향으로 건물의 손상이 시간에 따라서 진행되는 사례⁽¹¹⁾도 보고된 바 있다. 따라서 풍공학 분야에 종사하는 많은 연구자들은 바람에 의한 피해를 줄이고 바람에 안전한 구조물을 세우기 위한 많은 노력을 기울여 왔다. 특히, 풍하중을 받는 구조물의 동적 응답현상은 구조공학분야의 연구자들에게 많은 관심의 대상이 되어왔다. 구조물이나 그 구성요소들의 동적 응답현상을 연구하기 위해서는 먼저 구조물에 작용하는 하중변동성분들(loading fluctuations)의 특성을 분석해 보는 일이 중요하다. 이러한 하중변동성분들은 경계층 풍동에 설치된 구조물 모형이나 옥외에 설치된 실물 크기의 구조물에서 바람에 의해 생성될 수 있다.

풍동실험이나 옥외실험에서 구조물의 각 지점에 설치된 압력 탭에서 시간에 따라서 측정된 압력은 하나의 압력 시계열을 이루고 이러한 각 지점의 압력 시계열들이 모여서 하나의 양상을 형성한다. POD의 목적은 이러한 불규칙장의 양상을의 성질을 가장 밟은 확정적 함수를 식별하는 것이다. 불규칙 압력 $p(x, y, t)$ 가 주어졌을 때, 확정적 함수 $\Psi(x, y)$ 로의 $p(x, y, t)$ 의 투영의 최대치가 구해질 수 있다. 이 조건으로부터 평균제곱(mean-square)의 성질을 이용하여 다음과 같은

적분 방정식이 유도된다.

$$\int R_p(x, y, x', y') \Psi(x', y') dx' dy' = \lambda \Psi(x, y) \quad (1)$$

여기서 $R_p(x, y, x', y')$ 는 압력의 공간 공분산을 나타낸다. 식 (1)의 고유치 문제의 해는 POD 해석을 위한 기초가 된다. 고유함수 $\Psi(x, y)$ 는 불규칙 압력 $p(x, y, t)$ 을 표현하는 최적 함수들의 한 집합을 구성한다. 결과적으로 압력은 급수 전개에 의해서 다음과 같이 표현될 수 있다.

$$p(x, y, t) = \sum_n a_n(t) \Psi_n(x, y) \quad (2)$$

여기서 주좌표 $a_n(t)$ 은 정규 직교화된 고유함수를 이용하여 다음과 같이 표현된다.

$$a_n(t) = \int p(x, y, t) \Psi_n(x, y) dx dy \quad (3)$$

식 (2)에서 고유함수 $\Psi_n(x, y)$ 는 불규칙 압력 $p(x, y, t)$ 의 공간적인 특징을, 주좌표 $a_n(t)$ 는 불규칙 압력의 시간적인 의존도를 의미한다. 식 (2)와 (3)을 이용하여 압력의 평균제곱값 $\langle p^2(x, y) \rangle$ 을 고유치와 고유함수와 관련된 모든 전개에 의해서 나타낼 수가 있는데, 고유치는 압력의 평균제곱값의 급수전개에서 고유함수가 관여하는 정도를 나타낸다.

2.2 자기회귀 이동평균

구조물에 작용하는 풍압력을 근사적으로 모사하는 일은 풍공학 분야에서 상당한 관심의 대상이다. 시계열의 식별이나 예측 문제는 확률론적인 이론이나 신경망 이론을 사용하여 이루어질 수 있다. 이 절에서는 유한한 차수의 확률론적 선형 차분 방정식으로서 나타낼 수 있는 자기회귀 이동평균(autoregressive moving average) 모델에 대해서 소개하고자 한다.

AR(p)로서 나타내는 차수 p 의 자기회귀 모델에서, 시계열 데이터의 현재 값은 유한한 수의 이전 값들과 현재의 백색 잡음(white noise)을 선형적으로 결합함으로써 나타낼 수 있다. MA(q)로서 나

타내는 차수 q 의 이동평균 모델에서, 시계열 데이터의 현재 값을 유한한 수 q 개의 이전 백색 잡음에 선형적으로 의존한다. 차수 p 의 자기회귀 모델과 차수 q 의 이동평균 모델의 결합인 자기회귀 이동평균 모델은 ARMA(p, q)로서 나타내는데, 이 모델을 이용하여 시계열 $C(t)$ 는 다음과 같이 표현될 수 있다.

$$\begin{aligned} C_t &= \phi_1 C_{t-1} + \phi_2 C_{t-2} + \cdots + \phi_p C_{t-p} \\ &= z_t + \theta_1 z_{t-1} + \theta_2 z_{t-2} + \cdots + \theta_q z_{t-q} \quad (4) \end{aligned}$$

여기서 C_t 는 시간 t 에서의 정상(stationary) 과정 $C(t)$ 이고, z_t 는 평균 0과 유한 표준편차 σ_z 를 갖는 백색 잡음 과정이다. ϕ_1, \dots, ϕ_p 와 $\theta_1, \dots, \theta_q$ 는 각각 AR과 MA 모델 계수를 나타낸다. ARMA 모델의 매개변수들은 자기상관함수(ACF)와 부분자기상관함수(PACF)와 관련이 있다. 정상 시계열 $C(t)$ 의 ACF는 시간 t 에서의 C_t 와 이보다 시차 h 가 앞선 시간 $t+h$ 에서의 C_{t+h} 사이의 상관관계를 나타낸다. 또한 시계열 $C(t)$ 의 PACF는 C_t 와 C_{t+h} 를 중간의 관측값들인 $C_{t+1}, C_{t+2}, \dots, C_{t+h-1}$ 위로 선형적으로 회귀한 후 얻어진 두 잔차들(residuals)의 상관관계이다. 이 ACF와 PACF는 모델의 차수를 초기에 가늠해보기 위해 사용될 수 있다. 예를 들어, 한 시계열에 대하여 계산된 PACF의 크기가 p 보다 큰 시차에 대하여 0에 가깝게 무시할 수 있다면 차수 p 의 AR 모델이 가정된다. 반면 시계열의 ACF의 크기가 q 보다 큰 시차에 대하여 0에 가깝게 무시할 수 있다면 차수 q 의 MA 모델이 가정된다. ARMA 모델의 매개 변수들은 최대 가능도법(maximum likelihood method)⁽⁵⁾이나 최소제곱법(least squares method)⁽⁶⁾을 사용하여 추정될 수 있다.

AR 모델의 차수가 과대하게 선정되는 것을 방지하고 가장 적당한 차수를 찾기 위하여 몇 가지 모델 선정 기준들이 사용된다. 모델 차수를 최적화하기 위한 기준들로서 AICC(Akaike Information Criterion의 교정판), BIC(Bayesian Information Criterion)와 FPE(Final Prediction Error) 등이 있다. 이 기준들은 서로 다른 예측 결과를 산출하기 때문에 모델 차수를 선정하는 과정은 나소 해석자의 경험에 의존한다.

일단 하나의 시계열에 대해서 모델이 적합되면 이 모델이 유효한지 검사하는 일이 중요하다. 일반적으로 이러한 검사는 관측된 값과 적합된 모델로부터 얻어진 예측된 값을 비교함으로써 행해진다. 이 관측값과 예측값의 차이에 의해서 계산된 일단계 예측 오차를 산자라 한다. 만일 설정된 모델이 적합하다면 잔차의 시계열은 백색 잡음 과정과 유사해야 한다. 잔차는 다음과 같이 정의된다.

$$\hat{w}_t = (C_t - \hat{C}_t)/\sqrt{r_{t-1}} \quad (5)$$

여기서 \hat{C}_t 는 ARMA(p, q) 과정에 의해서 시간 $t-1$ 까지의 관측값을 사용하여 예측된 C_t 의 값이다. 또한 r_{t-1} 은 $E(C_t - \hat{C}_t)^2/\sigma_z^2$ 에 의해서 정의되는데, 여기서 E 는 기대값을 나타낸다.

2.3 신경망

우리 실험을 위한 실물 크기의 모형에서 축정된 풍압력 데이터는 데이터의 급격한 변동과 같은 비선형적인 성질이 강할 수 있다. 신경망(neural networks)은 데이터의 분포가 비선형 과정에 의해서 생성되고 비 Gaussian인 데이터의 해석에 적합한 기법으로 알려져 있다. 이 절과 3.3절에서는 신경망 이론과 그 적용 예를 간략히 소개하고자 한다.

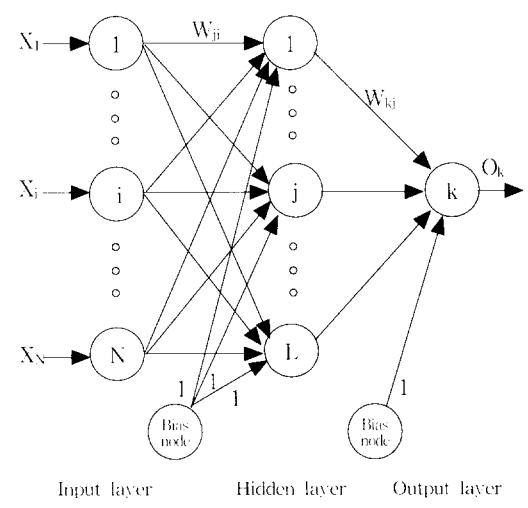


그림 1 역전파 신경망

역전파 신경망은 그림 1에 보여진 바와 같이 몇 개의 층으로 이루어져 있다. 이 그림에서 신경 망은 하나의 입력층, 은닉층과 출력층으로 이루어져 있고 각 은닉층과 출력층은 인공 뉴론(neuron)들로 구성되어 있다. 입력 벡터 $\mathbf{x} = [x_1, x_2, \dots, x_N]^t$ 가 망에 입력되면 i 번째 입력 절점에서 하나의 신호 x_i 는 가중치와 함께 은닉층과 출력층의 뉴론을 포함하는 연결관계를 통해 입력층에서 출력층으로 전해진다. 이러한 과정은 망의 뉴론 j 에 대하여 다음과 같이 표현될 수 있다.

$$net_j = \sum_{i=1}^N w_{ji} x_i + b_j \quad (6)$$

여기서 w_{ji} 는 j 번째 뉴론과 i 번째 절점 사이의 연결의 강도를 나타내는 가중치이고, b_j 는 바이어스이다.

한 뉴론의 출력은 미분 가능한 이전(transfer) 함수를 사용하여 생성될 수 있다. 그림 2는 S자 모양의 비선형 이전함수를 보여주고 있는데, 뉴론 j 에 대하여 비선형 이전함수 s_j 는 $tanh(net)$ 로 나타낼 수 있다. 이 이전 함수는 뉴론의 입력값이 음에서 양의 무한대로 감에 따라 -1과 1 사이의 출력값을 생성한다. 선형 이전함수가 뉴론의 출력을 생성하기 위하여 사용된다면, 한 뉴론으로의 전체 입력값은 이 뉴론의 출력값과 같을 것이다.

한 신경망 구조에 대하여 신경망은 하나의 훈련 단계를 거쳐 최적화 되는데, 이 때 입력 벡터들과 각 벡터에 상응하는 기지의 출력값이 사용된다. 각 입력 벡터에 대하여 망에 의해서 생성된 출력

값 o_k 는 기지의 목표값 y_k 와 비교되는데, 망의 출력오차인 총제곱오차는 다음 식에 의해 계산된다.

$$E = \sum_{k=1}^Q (y_k - o_k)^2 \quad (7)$$

여기서 Q 는 출력값의 수이다. 신경망 훈련의 목적은 위의 오차 E 를 최소화시키는 것인데, 이는 망의 가중치가 반복적으로 조정되는 학습을 통하여 이루어질 수 있다. m 번째 반복에 대하여 가중치의 변화값은 다음과 같다.

$$\Delta w_{ji}(m) = -\eta \frac{\partial E(m)}{\partial w_{ji}(m)} \quad (8)$$

여기서 η 는 학습율이다. 망이 훈련될 때 오차의 진동을 적게 하여 수렴속도를 빨리 하기 위하여 식 (8)에 가중치의 이전 변화값의 일부를 나타내는 모멘텀항이 추가될 수 있다. 학습율과 모멘텀항의 모멘텀 계수는 모두 1보다 작은 양의 수이다.

3. 결과 및 고찰

3.1 고유 직교 분해

풍동실험을 통하여 그림 3에 보여진 구조물 표면에 균일하게 분포된 494개의 탭에서 압력이 측정되었고, 이 압력을 이용하여 POD 해석이 이루어졌다. 실험 데이터는 일본 청수건설의 경계층 풍동에서 얻어진 것인데 압력 데이터는 667Hz의

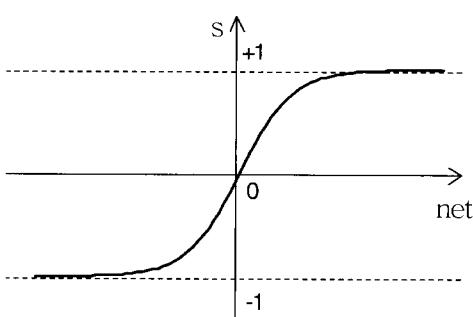


그림 2 비선형 이전 함수

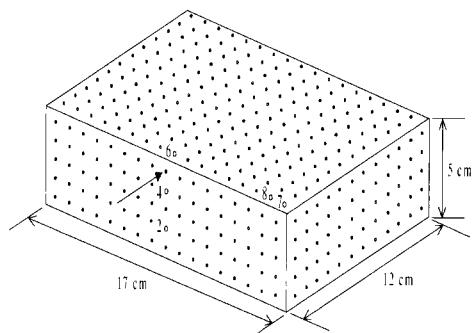


그림 3 구조물 모형과 압력탭의 위치

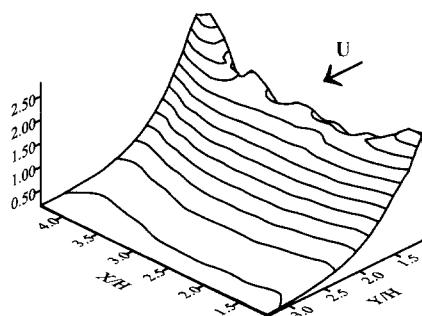


그림 4 모형 상면의 압력 평균제곱값

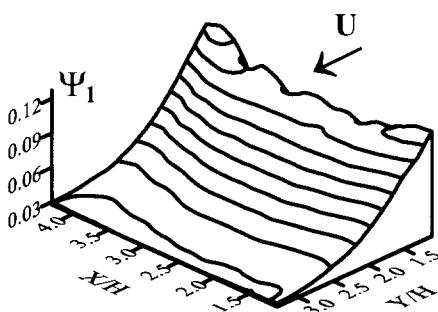


그림 5 모형 상면의 제 1 고유함수

조물 상면의 압력을 이용한 POD 해석의 대표적인 결과를 보여주고 있다. 표 1에 처음 10개를 포함하여 대표적인 정규화된 고유치가 나와 있는데, 제 1 고유치는 다른 고유치들 보다 두 자리 더 많다는 것을 알 수 있다. 이 사실은 식(2)의 압력의 급수전개에서 비교적 적은 수의 항이 풍압력의 공간적·시간적인 특징을 나타내기 위해서 필요로 된다는 것을 의미한다. 그림 5는 구조물 상면에서의 제 1 고유함수의 분포를 보여주고 있는데, 이 고유함수의 분포형상은 그림 4의 압력 평균제곱값의 분포형상과 유사함을 알 수 있다.

그림 6에서는 구조물 상면의 최대 부압력을 나타내는 텁 8에서 측정된 지점압력이 POD 결과를 이용한 모드 재합성(reconstruction)으로부터 얻어진 압력과 비교되고 있다. 구조물 상면의 압력과 관련된 204개의 POD 모드들 중에서 60개의 모드가 사용될 때 지점 최대압력의 재합성이 잘 이루어짐을 알 수 있다.

표 1 압력 고유치

POD 모드	압력 고유치
1	160.29
2	1.71
3	1.60
4	1.17
5	0.62
6	0.58
7	0.53
8	0.41
9	0.37
10	0.30
50	0.05
100	0.02
200	0.01

빈도로 수집되었다. 그림 4는 구조물 전면에 수집한 바람에 기인한 구조물 상면의 압력 평균제곱값의 분포를 보여주고 있다. 표 1과 그림 5는 구

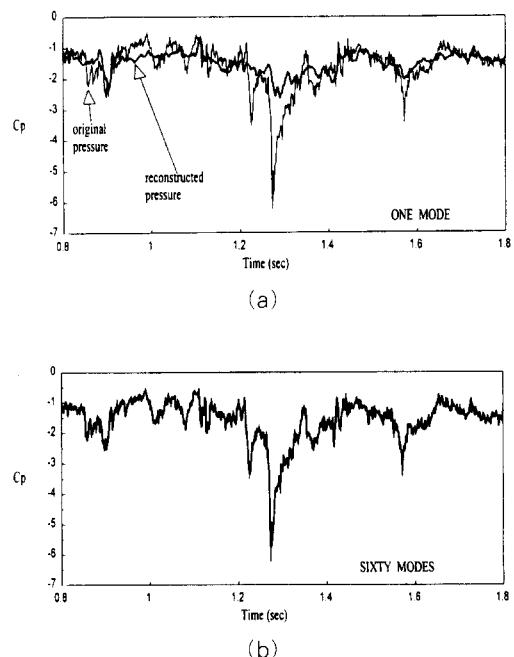


그림 6 측정된 압력과 (a) 1 모드와 (b) 60 모드를 사용하여 재합성된 압력의 비교

3.2 자기회귀 이동평균

그림 3에 보여진 구조물의 전면에 위치한 텁 2와 4, 구조물 상면에 위치한 텁 6과 7에서 측정된 지점 압력 시계열에 대한 AR 모델이 개발되었다. 구조물 전면의 텁 4에서의 압력 시계열이 그림 7에 보여진다.

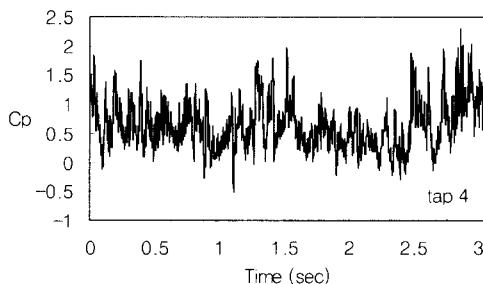


그림 7 구조물 전면의 압력

모델의 선정은 프로그램 ITSM⁵⁾을 사용하여 이루어졌다. 압력 시계열의 모델링 과정에서 ACF와 PACF가 먼저 계산되었는데, 텁 4의 압력에 대한 ACF와 PACF가 그림 8에 보여진다. 이 그림에서 PACF의 겹토 결과 비교적 낮은 차수의 AR 모델이 가정된다. PACF에 근거한 대표적인 지점 압력들의 AR 모델 차수가 표 2의 2열에 나와 있는데, 모델 차수는 5에서 8에 이른다.

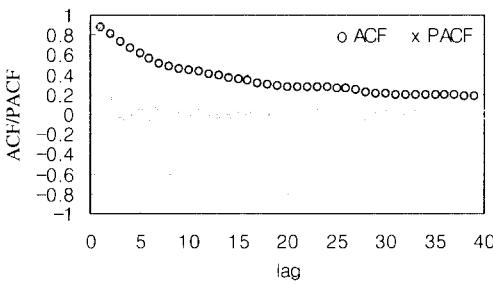


그림 8 압력의 ACF와 PACF

표 2 압력의 AR 모델의 차수

압력	AR 차수 (p)			
	PACF	FPE	BIC	AICC
텅 2	6	6	2	9
텅 4	8	5	2	11
텅 6	5	8	2	9
텅 7	5	5	5	5

모델의 매개 변수들은 최대 가능도법을 사용하여 결정되었다. 모델 차수의 최적화를 위해서 모델 선정 기준들인 FPE, BIC와 AICC가 사용되었는데, 각 선정 기준에 대해서 선정 기준값을 최소화시키는 AR 차수 p 가 적당한 차수로 선정되었다. 각 기준에 대하여 선정된 모델의 차수가 표 2의 3열에서 5열에 나와 있다. 모델 차수의 최종적인 선정은 AICC 기준에 의해서 결정되었고, 이 결과는 표 2의 5열에 보여진다.

그림 9는 텁 4의 압력에 대한 AR 모델 잔차 계열의 ACF를 보여준다. 이 그림에서 잔차 계열의 ACF는 잔차 계열이 백색 잡음 과정을 이룬다는 가정과 일치함을 보여주는데, 이는 선정된 모델이 압력 데이터의 중요한 성질을 잘 나타내고 있음을 의미한다.

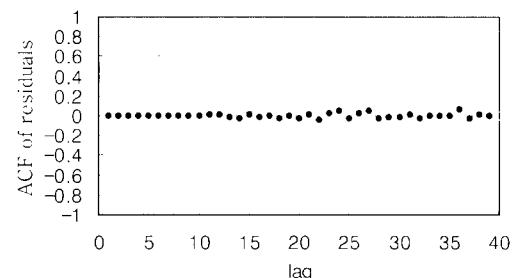


그림 9 압력의 AR 모델 잔차 계열의 ACF

3.3 신경망

그림 3과 유사한 구조물의 상면에서 측정된 압력 시계열을 사용하여 신경망 모델링이 이루어졌다. 경계층 풍동실험에서 얻어진 실험 데이터의 수집 빈도는 500Hz이었다. 그림 10은 구조물의 상면에서

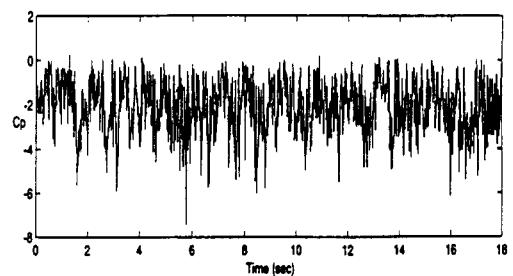


그림 10 구조물 상면의 압력

측정된 압력 시계열을 보여준다. 이 압력 시계열은 9000개의 데이터로 이루어져 있는데, 처음 4000개의 데이터가 신경망을 훈련시키기 위하여 사용되었다. 시계열의 나머지 데이터는 개발된 신경망의 유효함을 검사하기 위하여 쓰여졌다.

신경망 모델링은 MATLAB¹²⁾ Toolbox를 사용하여 이루어졌다. 역전파 신경망이 0.7의 학습율과 0.9의 모멘텀을 사용하여 훈련되었고 망의 훈련의 최대 반복회수는 3000이었다. 망의 훈련을 위해 압력 시계열의 연속적인 N 개의 값이 망에 입력되었고 이에 대한 출력값은 다음 시간인 $N+1$ 에서의 압력 데이터의 값과 비교되었다. 그림 11은 망의 학습 과정을 나타내는데, 여기서 총제곱오차 E 가 학습 반복회수의 함수로 그려져 있다. 이 그림에서 오차는 반복회수가 약 100에 이를 때까지 급격히 감소하고, 100 이후의 반복회수에서는 오차의 감소율이 매우 적음을 알 수 있다. 고려된 압력 시계열에 대하여 적합한 신경망을 찾기 위하여 입력층과 은닉층의 절점 수를 변화시키면서 몇 가지 신경망 구조가 검사되었다. 이 검사는 처음 4000개의 데이터를 사용하여 훈련된 망에 의하여 일단계 예측된 나머지 5000개의 데이터와 이에 상응하는 측정 데이터를 비교함으로써 이루어졌다. 이 비교를 통하여 평균제곱오차의 제곱근이 계산되는 데 이 오차가 가장 작은 신경망 구조가 압력 시계열에 적합한 것으로 여겨졌다. 고려된 압력 시계열에 대하여 14개의 입력 값과 7개의 뉴론을 갖는 신경망 구조가 가장 적합한 것으로 결정되었다. 표 3은 압력 시계열과 가장 적합한 신경망을 사용하여 일단계 예측된 시계열의 통계적 특성을 보여주고 있는데, 비교된 두 시계열의 통계적 특성이 매우 유사함을 알 수 있다.

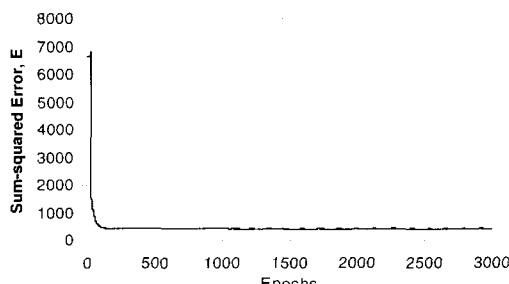


그림 11 총제곱오차

표 3 측정 압력과 신경망에 의해서 생성된 압력의 통계적 특성

	평균치	표준 편차	양의 최대값	부의 최대값
측정 압력	2.201	1.047	0.228	-6.177
생성 압력	-2.199	1.007	0.242	-5.896

4. 결 론

본 기사에서는 경계층 풍동실험에서 얻어진 풍속이나 풍압과 같은 풍동실험 데이터의 분석을 위한 몇 가지 기법들이 소개되었다. 첫째, 고유직교분해가 구조물에 작용하는 풍하중에 적용되었다. 이 POD 해석에서 얻어진 고유함수와 주좌표는 풍압력을 재합성하기 위해 사용되었는데, 적은 수의 POD 모드를 이용하여 지점최대 부압력의 재합성이 잘 이루어졌다. 이를 통해 POD는 방대한 양의 풍하중 데이터의 해석과 축소에 유용함을 확인할 수 있었다.

둘째로, 균일하게 샘플된 풍압력의 시간적인 특성을 조사하기 위해 선형 자기회귀 모델이 사용되었다. 구조물에 작용하는 풍압력 시계열에 대하여 선정된 AR 모델의 차수는 데이터의 시간적인 복잡성을 나타내는 한 척도이다. 풍압력 시계열의 AR 모델은 구조물에 작용하는 풍하중을 생성하기 위해 사용될 수 있다.

끝으로, 구조물에 작용하는 풍압력을 균사적으로 모사하기 위해서 역전파 신경망이 사용되었다. 입력층과 은닉층의 절점 수가 망의 훈련에 미치는 영향이 고려되었는데, 비교적 적은 수의 뉴론을 갖는 한 개의 은닉층으로 이루어진 신경망이 고려된 풍압력을 잘 모사하였다. 본 기사에서 소개된 역전파 신경망 기법은 구조물의 풍압력의 분포를 예측하기 위하여 적용될 수 있는데, 이 때 망을 훈련시키기 위하여 충분한 실험 데이터가 주어져야 한다. 신경망은 비선형 데이터에 적합한 것으로 알려져 있는 등 강력한 데이터 해석 기법이지만, 적당한 신경망 구조를 선정하는 일은 시간이 걸리는 시행착오의 과정이다. 따라서, 풍압력 시계열의 예측을 위하여 신경망을 능률적으로 설계하는 방법이 필요로 되고 있다.

참 고 문 헌

1. Armitt, J., "Eigenvector analysis of pressure fluctuations on the West Burton instrumented cooling tower," Central Electricity Research Laboratories (U.K.), Internal Report RD/L/N, 114/68, 1968
2. Bienkiewicz, B., Ham, H. J. and Sun, Y., "Proper orthogonal decomposition of roof pressure," *J. Wind Eng. Ind. Aerodyn.*, Vol. 50, 1993, pp.193~202
3. Davenport, A. G., "How can we simplify and generalize wind loads?," *Third Asia-Pacific Symposium on Wind Eng.*, Vol. 1, Dec. 13-15, 1993, pp.15~26
4. Tamura, Y., Ueda, H., Kikuchi, H., Hibi, K., Suganuma, S. and Bienkiewicz, B., "Proper orthogonal decomposition study of approach wind-building pressure correlation," *Proc. of the 9th Int. Conf. on Wind Eng.*, New Delhi, India, 1995, pp.2115~2126
5. Jeong, S. H., "Analysis of building wind pressure using proper orthogonal decomposition, autoregressive moving average and neural networks," Ph.D. Dissertation, Dept. of Civil Engr., Colorado State University, Fort Collins, Colorado, 1998
6. Brockwell, P. J. and Davis, R. A., *Time series: theory and methods*, 2nd Ed., Springer-Verlag, 1991
7. Fortier, L. J. and Scanlan, R. H., "A cooling tower wind loading model based on fullscale data," *Proc. of the 5th Int. Conf. on Wind Eng.*, J. E. Cermak (Editor), Fort Collins, Colorado, Pergamon Press, 1979, pp.1217~1226
8. Stathopoulos, T. and Mohammadian, A. R., "Modeling of wind pressures on monoslope roofs," *Eng. Struct.*, Vol. 13, 1991, pp.281~292
9. Turkkan, N. and Srivastava, N. K., "Prediction of wind load distribution for air-supported structures using neural networks," *Can. J. Civ. Eng.*, Vol. 22, 1995, pp.453~461
10. Khanduri, A. C., Bedard, C. and Stathopoulos, T., "Neural network modeling of wind-induced interference effects," *Proc. 9th Int. Conf. on Wind Eng.*, New Delhi, India, 1995, pp.1341~1352
11. Sandri, P. and Mehta, K. C., "Using a back-propagation neural network for predicting wind induced damage to buildings," *Proc. 9th Int. Conf. on Wind Eng.*, New Delhi, India, 1995, pp.989~1999
12. MATLAB-Neural Network Toolbox Users Guide, The MathWorks, Inc., Natick, Mass., 1994 [N]