

인공신경망 기법과 유전자 기법을 혼합한 결함인식 연구

서명원*, 심문보**

Crack Identification Using Hybrid Neuro-Genetic Technique

Myung Won Suh*, Mun Bo Shim**

ABSTRACT

It has been established that a crack has an important effect on the dynamic behavior of a structure. This effect depends mainly on the location and depth of the crack. To identify the location and depth of a crack in a structure, a method is presented in this paper which uses hybrid neuro-genetic technique. Feed-forward multilayer neural networks trained by back-propagation are used to learn the input(the location and depth of a crack)-output(the structural eigenfrequencies) relation of the structural system. With this neural network and genetic algorithm, it is possible to formulate the inverse problem. Neural network training algorithm is the back propagation algorithm with the momentum method to attain stable convergence in the training process and with the adaptive learning rate method to speed up convergence. Finally, genetic algorithm is used to find the minimum square error.

Key Words : Crack identification (결함인식), Neural network (인공신경망), Structure analysis (구조해석), Genetic algorithm (유전자 알고리즘), Inverse analysis method (역해석 방법)

1. 서론

최근 구조물의 결함진단을 위해 다양한 방법들이 적용되고 있다. 특히, 구조물의 동특성 즉, 모달파라메타(modal parameter)를 이용하여 진단하는 방법이 널리 연구되고 있다. 모달파라메타 중 고유진동수는 구조물의 결함에 대해 민감한 반응을 나타내므로 효과적인 결함진단 파라메타로 할 수 있다. 결함진단을 위해서는 결함 유무, 결함 위치, 결함 정도를 파악해야하나 이는 매우 난해한 문제이다. 이를 해결하기 위해 현장실험을 통하여 얻은 계측

자료와 수학적 모델을 이용하여 구조물의 결함 위치 및 결함 정도를 파악하는 기술인 역해석 방법(inverse analysis method)이 크게 대두되고 있다. 역해석 방법은 여러 가지 다양한 문제의 해석에 적용되어 왔으며 그중 실제 구조물 내에 존재하는 결함, 특히 크랙의 크기와 위치를 찾아내는 분야는 구조물의 건전성 확보 및 보수작업이 빠르게 이루어질 수 있으므로 매우 중요하다.

구조물내의 크랙을 인식하는 연구는 다양한 방법으로 접근되어 왔다. Chondros와 Dimarogonas^{(1), (2)}는 크랙을 전체 구조물의 탄성에 영향을 주는 국부탄성체(스프링)로 간주하였고 크랙의 깊이가 고유

* 성균관대학교 기계공학부
** 성균관대학교 대학원 기계공학과

진동수의 감소와 관계한다고 주장했다. Gounaris와 Dimarogonas⁽³⁾은 특별히 그랙이 있는 보를 유한요소모델로 구성하였다. Gounaris와 Papazoglou⁽⁴⁾는 크랙이 있는 Timoshenko 보의 동적 거동을 연구하기 위하여 변형된 유한 경계 요소법을 사용하였다. 위의 연구 결과를 배경으로 Inagaki⁽⁵⁾등은 고유진동수를 측정하여 크랙의 깊이와 위치를 알아내었고, Leung⁽⁶⁾과 Anifantis⁽⁷⁾ 등은 회전축의 동적거동을 측정하여 크랙을 인식하는 방법을 제안하였다. Dimarogonas와 Massourous⁽⁸⁾는 크랙이 있고 비틀림을 받는 축의 동적거동을 조사하였고 크랙의 깊이와 위치를 알아내기 위해 nomographs를 제안했다. Nikolakopoulos, Katsareas, 그리고 Papadopoulos⁽⁹⁾는 크랙에 의해 발생된 구조물의 고유진동수 변화율을 측정하여 크랙의 깊이와 위치를 파악해 낼 수 있도록 고유진동수 변화율에 대한 크랙의 위치관계를 보여주는 등고선을 제안했다. 이 이론의 기본적인 개념은 유한요소법과 더불어 크랙의 위치와 크기에 따라 달라지는 구조물의 고유진동수 중 처음에 나타나는 세 개의 고유진동수를 이용하여 이 세 개의 고유진동수 변화율과 크랙의 크기 및 위치를 서로 대응하게 하는 등고선을 그리는 방법을 제시했다. 그러므로 실제 구조물에 존재하는 크랙으로 인해 발생되는 고유진동수의 변화율을 측정하여 이러한 등고선을 구성하면 등고선들의 교차점으로부터 크랙의 크기와 위치를 알아낼 수 있었다. 하지만 등고선 작성 및 교차점들을 찾기 위해서는 많은 시간과 노력이 필요하기 때문에 이와 같은 방법은 효과적이라 할 수 없다.

본 연구에서는 유한요소법을 이용한 보 모델을 설립하고 크랙이 있는 구조물의 고유진동수를 구하여 이를 인공신경망을 통해 학습한 후 크랙을 인식하기 위한 역해석의 해를 구하기 위해 유전자 알고리즘을 이용함으로써 효과적인 크랙의 크기와 위치를 찾을 수 있었다.

2. 이론

2.1 역해석

일반적으로 매개변수의 결정방법은 기지의 변수를 이용하여 미지의 변수를 결정하는 역해석 방법이 많이 사용되어져 왔다. 해석에 관련된 미지의 매개변수(벡터)를 $x^* \in X$ 라하고 측정변수(벡터)

를 $y^* \in Y$ 라 할 때, $\Psi: X \rightarrow Y$ 의 함수 관계가 성립한다고 하면, 실제 입력변수와 출력변수와의 관계는 다음과 같이 나타낼 수 있다.

$$y = \Psi(x) + \varepsilon \quad (1)$$

이 때, $\varepsilon = \varepsilon_1 + \varepsilon_2$ 이고 ε_1 과 ε_2 는 각각 변수 y 를 측정할 때 발생하게 되는 측정 오차와 상태 방정식을 이용하여 모델링을 세울 때 발생하게 되는 모델링 오차이다. 이와 같은 함수의 역관계를 Fig. 1에 일반적인 계의 변수와 이와 관계된 해석영역 및 경계면에 대해 나타내었다.⁽¹⁰⁾

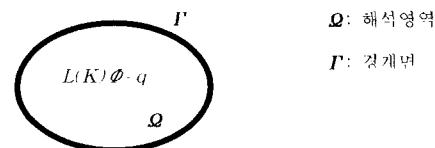


Fig. 1 Problems of field quantities

여기서, 일반적인 계의 역함수 관계는 식 (2)와 같다.

$$L(K)\Phi = q \quad (2)$$

이 때, L, K, Φ 그리고 q 는 각각 미분 연산자, 재료의 고유 물성치, 영역변수, 그리고 가해진 외력 및 그 이외의 입력자료를 나타낸다. 이와 같은 역해석 문제의 해를 구하는 방법은 실제로 많은 어려움이 있을 수 있다. 가령 함수의 관계가 일대일대응이 아니라면 역함수를 구하는 것은 불가능한 일이고 구한다하더라도 잘못된 값을 구하게 된다. 이를 해결하기 위해 새로 함수를 구성하고 이 함수의 최소 및 최대 값을 구하여 역함수의 해를 얻는 것이다. 일반적으로 목적함수를 최소화하여 미지의 매개변수를 구하는 방법이 가장 널리 사용되어지고 있다. 식 (3)은 목적함수를 최소화하여 역해석 해를 구하기 위한 문제정의를 나타낸다.

$$\min f(x) \quad (3)$$

$$f(x) = \sum_{i=1}^n k_i (y_i^* - \Psi_i(x))^2$$

여기서, k_i 는 가중치(weighting factor)이고 이와 같이 구성된 식을 최소화하여 이에 대응되는 매개변수 x 의 값을 구할 수 있다.

본 연구에서는 크랙의 유무를 인식하기 위해 역해석 방법을 이용하였는데 먼저 유한요소모델로부터

터 그랙이 존재할 경우 사용 채 개의 고유진동수와 그랙의 크기 및 위치와의 관계를 구하고 이를 선상망 이론(neural network)으로 학습하고 임의의 채 개의 고유진동수에 대한 그랙의 크기와 위치를 인식하기 위해 유전자 알고리즘(genetic algorithm)을 적용하여 식(3)의 복잡함수를 최소화하였다.

2.2 구조 해석

평면 구조물은 3개의 자유도 ($\delta_x, \delta_y, \theta_z$)를 가진 2차원 보(beam) 요소를 이용하여 모델링할 수 있다. 이러한 평면 구조물에 대응되는 강성(stiffness)과 질량(mass)의 local matrix는 식(4)와 식(5)이다.⁽⁹⁾

$$[K_e] = \frac{EI_{zz}}{L^3} \begin{bmatrix} \beta L^2 & 0 & 0 & -\beta L^2 & 0 & 0 \\ 0 & 12 & 6L & 0 & -12 & 6L \\ 0 & 6L & 4L^2 & 0 & -6L & 2L^2 \\ -\beta L^2 & 0 & 0 & \beta L^2 & 0 & 0 \\ 0 & -12 & -6L & 0 & 12 & -6L \\ 0 & 6L & 2L^2 & 0 & -6L & 4L^2 \end{bmatrix} \quad (4)$$

$$[M_e] = \frac{\rho A L}{420} \begin{bmatrix} 140 & 0 & 0 & 70 & 0 & 0 \\ 0 & 156 & 22L & 0 & 54 & -13L \\ 0 & 22L & 4L^2 & 0 & 13L & -3L^2 \\ 70 & 0 & 0 & 140 & 0 & 0 \\ 0 & 54 & 13L & 0 & 156 & -22L \\ 0 & -13L & -3L^2 & 0 & -22L & 4L^2 \end{bmatrix} \quad (5)$$

여기서, $\beta = A/I_{zz}$, L 은 요소 e 의 길이, A 는 요소의 단면적, E 와 ρ 는 각각 재료의 탄성계수와 밀도를 의미한다. 그리고 I_{zz} 는 local z 축에 대한 2차 관성모멘트를 의미한다.

위에 제시된 구조물은 Euler-Bernoulli 이론으로부터 힘 평형 방정식과 변형의 기하학적 관계, 재료의 법칙을 이용하여 보 element의 한쪽 끝단의 상태변수(하중, 변위)와 반대쪽 끝단의 상태변수관계를 나타내는 transfer matrix가 계산되어지며 식(6)과 같다.

$$[T_e] = \begin{bmatrix} 1 & 0 & 0 & -\frac{L}{AE} & 0 & 0 \\ 0 & 1 & L & 0 & \frac{L^3}{6EI_{zz}} & \frac{-L^2}{6EI_{zz}} \\ 0 & 0 & 1 & 0 & \frac{L^2}{2EI_{zz}} & \frac{-L}{6EI_{zz}} \\ 0 & 0 & 0 & -1 & 0 & 0 \\ 0 & 0 & 0 & 0 & -1 & 0 \\ 0 & 0 & 0 & 0 & L & -1 \end{bmatrix} \quad (6)$$

Fig. 2는 끝단에서 거리 L_{ie} 만큼 떨어져 있고 깊이 a 인 위치에 crack을 가지고 있는 beam의 모

습을 보여 주고 있다.

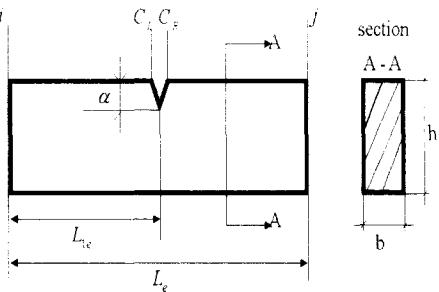


Fig. 2 A cracked beam finite element

위치 i , C_L , C_R , 그리고 j 에서의 상태 벡터는 식 (7a) ~ (7d)에 나타나 있다.

$$\{z_i\} = \{\delta_{x_i}, \delta_{y_i}, \theta_{z_i}, F_{x_i}, F_{y_i}, M_{z_i}\} \quad (7a)$$

$$\{z_L\} = \{\delta_{x_L}, \delta_{y_L}, \theta_{z_L}, F_{x_L}, F_{y_L}, M_{z_L}\} \quad (7b)$$

$$\{z_R\} = \{\delta_{x_R}, \delta_{y_R}, \theta_{z_R}, F_{x_R}, F_{y_R}, M_{z_R}\} \quad (7c)$$

$$\{z_j\} = \{\delta_{x_j}, \delta_{y_j}, \theta_{z_j}, F_{x_j}, F_{y_j}, M_{z_j}\} \quad (7d)$$

여기서 i, j 는 보 element의 양 끝단의 위치를 나타내며 R, L 은 크랙의 좌우위치, z 는 각 지점의 상태변수를 의미한다. 노드 i 와 j 사이에 어떠한 힘도 작용하지 않는다면 식 (8a) ~ (8c)가 성립된다.

$$\{z_L\} = [T_1]\{z_i\} \quad (8a)$$

$$\{z_R\} = [T_c]\{z_L\} \quad (8b)$$

$$\{z_j\} = [T_2]\{z_R\} \quad (8c)$$

[T_1]과 [T_2]는 노드 C_L-i 와 C_R-j 사이의 관계를 나타내는 transfer matrix이다. 그리고 [T_c]는 구조물내에 존재하는 crack의 두 점 C_L-C_R 의 관계를 나타내는 point transfer matrix이다. 식 (8a) ~ (8c)부터 식 (9)이 얻어지고 식 (10)은 point transfer matrix를 나타낸다.

$$\{z_j\} = [T_e^c]\{z_i\} \quad (9)$$

$$[T_e^c] = \begin{bmatrix} 1 & 0 & 0 & c_{11} & 0 & c_{13} \\ 0 & 1 & 0 & 0 & c_{22} & 0 \\ 0 & 0 & 1 & c_{31} & 0 & c_{33} \\ 0 & 0 & 0 & -1 & 0 & 0 \\ 0 & 0 & 0 & 0 & -1 & 0 \\ 0 & 0 & 0 & 0 & 0 & -1 \end{bmatrix} \quad (10)$$

식 (10)에서 밑 첨자 1, 2 그리고 3은 인장, 전

나. 그리고 굽힘을 의미한다. 예를 들어 c_{11} 과 c_{33} 항은 1과 3을 가지고 있으므로 인장과 굽힘이 작용되고 있음을 의미한다.⁽³⁾ 여기서 c_{12} 와 c_{31} 항은 고려되지 않고 c_{11} , c_{22} 그리고 c_{33} 항이 고려된다. 식 (11a)~(11c)는 c_{11} , c_{22} 그리고 c_{33} 을 표현한 것이다.⁽¹¹⁾

$$c_{11} = \frac{2\phi_1}{E(1-\nu^2)} \quad (11a)$$

$$c_{22} = \frac{2k^2\phi_3}{E(1-\nu^2)} \quad (11b)$$

$$c_{33} = \frac{72\phi_2}{E(1-\nu^2)b^2} \quad (11c)$$

여기서, ν 는 Possion's ratio, k 는 사각 단면 계수로 1.5이다. 그리고 ϕ_i 는 무차원 crack 깊이 $\frac{a}{h}$ 에 대한 함수이다.⁽¹²⁾ Fig. 3은 순수 인장, 굽힘, 전단상태에서 시편에 하나의 edge notch가 존재하는 경우 응력 집중 계수 K_I 를 구하기 위해 Tada⁽¹³⁾에 의해 제안된 실험으로 구해진 그래프이다.

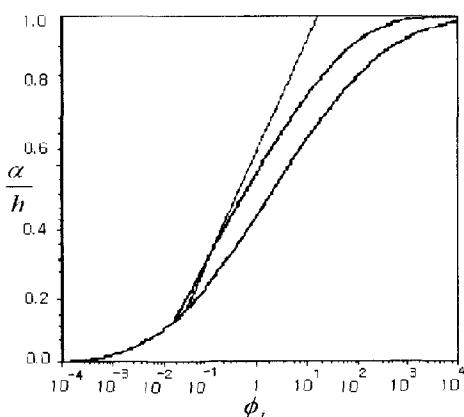


Fig. 3 ϕ_i vs $\frac{a}{h}$ for single edge notch specimen under pure tension and bending and shear

Crack의 발생된 요소의 transfer matrix는 식 (12)과 같다.

$$[T_e] = [T_2][T_d][T_1] = \begin{bmatrix} [A_1] & [A_2] \\ [A_3] & [A_4] \end{bmatrix} \quad (12)$$

여기서, $[A_i]$ 는 3×3 submatrices이다. 식 (13)은 그레이드 포함된 요소의 강성 행렬(stiffness matrix)이다.

$$[K_e] = \begin{bmatrix} -[A_1]^{-1}[A_1] & [A_2]^{-1} \\ [A_3]^{-1}[A_4][A_2]^{-1}[A_1] & [A_4][A_2]^{-1} \end{bmatrix} \quad (13)$$

이로부터 크랙이 존재하는 구조물에 대한 운동 방정식을 행렬형태로 나타내면 식 (14)와 이를 이용하여 고유 진동수를 구할 수 있다.⁽⁹⁾

$$-\omega^2[M] + [K] = \{0\} \quad (14)$$

본 연구에서는 식 (14)를 이용하여 크랙의 크기와 위치에 대한 고유진동수를 구하고 이를 인공신경망으로 학습하였다. 이는 해당 주파수에 대한 크랙의 크기 및 위치를 구하는 시간을 단축할 뿐만 아니라 학습을 통해 미지의 입력에 대한 결과까지도 예측하는 신경망의 장점을 이용하기 위함이다. 이로부터 미지의 고유진동수에 대한 크랙의 크기 및 위치를 알기 위한 유전자 알고리즘에 신경망의 학습된 결과를 적용하였다.

2.3 인공신경망 및 유전자 알고리즘

2.3.1 인공신경망

인공신경망은 인간이나 동물들이 가지고 있는 생물학적인 뇌의 신경 세포(neuron)를 모델화하여 인공적인 지능을 만드는 것이다. 이러한 신경망에서 중요한 구성 요소는 처리기(processing element)와 이들 상호간의 연결(interconnection)이다. 신경 세포의 인공적인 모델을 처리기 또는 유닛(unit)이라 하는데 이는 한 처리기에 연결된 다른 처리기들로부터의 입력에 연결선의 가중치를 고려하여 더한 후 그 결과를 적당한 활성화 함수로 처리하여 연결된 다른 처리기로 출력한다. 이를 수식적으로 표현하기 위해 하나의 처리기와 연결된 다른 처리기들의 출력 x_i 를 해당하는 두 처리기 사이의 연결강도 w_i 로 곱한 값들의 합 즉, net를 다음과 같이 계산할 수 있다.

$$\text{net} = \sum_{i=1}^n w_i x_i \quad (15)$$

이 합을 다음과 같은 활성화함수에 적용시켜서 얻은 결과를 그 처리기의 출력으로 하여 이와 연결되어 있는 다른 처리기로 보낸다.

$$y = f(\text{net}) \quad (16)$$

여기서, 활성화함수 $f(\text{net})$ 는 신경 세포의 반응 일부를 설정하는 역할을 한다. 현재 제안된 다양한 신경망 모델은 계층수, 출력 형태, 데이터 유형, 학습 방법 그리고 활성화 함수와 같은 기준에 따라 분류할 수 있는데, 본 연구에서는 신경망 모델 중 단층 및 순환 신경망인 역전파 인공신경망을 사용하였다. 역전파 학습 알고리즘은 두 단계의 순서에 의해 이루어진다고 볼 수 있는데, 첫 번째 단계에서는 입력을 네트워크에 제시하면 이것이 네트워크의 전방향으로 전파되어 출력을 내고, 이 출력과 목표 출력과의 차이에 비분개수를 곱하여 출력 뉴런에 대한 오차를 계산한다. 두 번째 단계에서는 오자신호가 네트워크의 역방향으로 전파되어 가면서 각 뉴런의 오차 신호가 계산되고, 이것을 바탕으로 연결강도를 수정한다.⁽¹¹⁾ 이러한 네트워크를 도식적으로 나타낸 것이 Fig. 4이다.

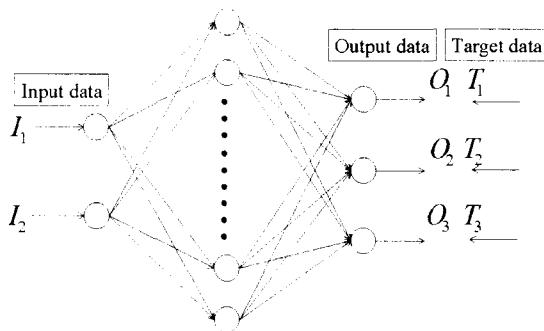


Fig. 4 Three-layer neural network

Fig. 4에서 알 수 있듯이 모든 유닛은 연속적인 층들 사이에 단지 순방향 연결로만 이루어진 입력 층, 은닉층, 출력층을 형성한다. 역전파 인공신경망의 학습 즉, 지도학습을 위한 기본인 개념은 식(17)의 정의에서 시작된다.

$$E = \sum_{p=1}^m E_p = \sum_{p=1}^m \sum_{k=1}^n (T_{pk} - O_{pk})^2 \quad (17)$$

여기서 E_p 는 p 번째 학습패턴에 대한 오차의 제곱합을 의미하며 n 은 출력 유닛의 수, m 은 패턴 수. T_{pk} 는 p 번째 학습패턴에 대한 k 유닛의 목표값. O_{pk} 는 p 번째 학습패턴에 대한 출력값을 나타낸다. 학습과정 동안 연결강도는 steepest gradient descent

method에 의해 수정되고 출력값이 목표값에 균사하게 되었을 때 학습이 종료된다.

본 연구에서는 활성화 함수로 시그모이드(sigmoid) 함수를 사용하였고 입·출력을 0.1~0.9로 스케일링하였으며 은닉층의 수는 13개를 사용하였다. 또한 역전파 학습 알고리즘의 향상을 위해 모멘텀과 적응 학습률을 이용하였다.

2.3.2 유전자 알고리즘

유전자 알고리즘은 진화 알고리즘 중 하나로 자연진화의 모델에 기초를 둔 확률 최적화 알고리즘이다. Fig. 5에는 기본적인 유전자 알고리즘의 구조를 나타내고 있다.

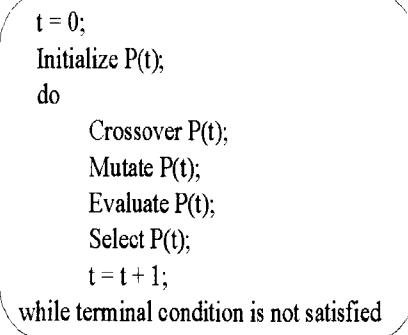


Fig. 5 Fundamental structure of GA

Fig. 5에서 알 수 있듯이 유전자 알고리즘은 3가지 연산자(operator) 즉, 교배(crossover), 돌연변이(mutation), 선택(selection)을 이용하여 진화과정을 인위적으로 수행하는 것으로 각 연산자의 역할과 최적화과정에 대한 기본개념을 다음 네 가지로 분류할 수 있다.⁽¹⁴⁾

- 1) n 개의 염색체(chromosome)로 구성된 최초 유전자 집단을 무작위로 구성
- 2) 다음 세대를 구성하는 염색체 후보들을 선별하는 과정으로서 적합도가 높은 개체를 확률적인 방법으로 선택
- 3) 선택된 유전자들 중에서 확률적으로 선택된 한 쌍씩을 상호교배시켜 새로운 염색체 구성
- 4) 어떤 유전자가 미쳐 겹증 받지 못하고 도태되는 것을 방지하기 위해 미리 주어진 확률에 의해 돌연변이 시키는 것으로 최적의 값을 구하

기 위한 수단으로 이용

이와 같이 유전자 알고리즘은 각 세대에서 적합도가 낮은 열성 유전자는 도태시키고 우성개체들끼리 상호교차 시켜서 우수한 새로운 세대를 만드는 과정을 반복적으로 수행함으로서 최적해를 구하게 된다.

3. 수치해석 적용 및 결과

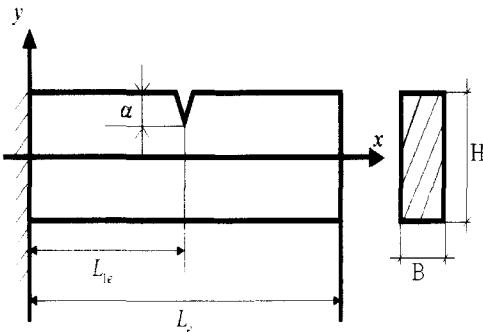


Fig. 6 Model of the cracked clamped-free beam

Fig. 6에 길이 $L = 3\text{ m}$ 이고 단면이 $B \times H = 0.2\text{m} \times 0.2\text{m}$ 끝단에서부터 길이 L_1 만큼 거리가 떨어져 있고 깊이 α 인 지점에 크랙을 포함하고 있는 clamped-free 보의 모습을 보여주고 있다. 이 때, 재료 물성치는 $E = 2.07 \times 10^{11}\text{ Nm}^{-2}$, $\nu = 0.3$ 그리고 $\rho = 7700\text{ kgm}^{-3}$ 이다.

먼저 크랙이 있는 경우의 강성행렬식(4)와 질량행렬식(6)을 적용하여 크랙의 깊이와 위치를 알 경우 그 때의 고유진동수를 계산하고 이를 인공신경망을 이용하여 학습시켰다. 고유진동수의 계산을 위해 크랙의 깊이를 $0.01 \sim 0.1\text{ m}$ 까지 10등분하였으며 크랙의 위치를 $0.1 \sim 2.9\text{ m}$ 까지 29등분하였다. 인공신경망 학습을 위해 입력층은 크랙의 깊이(α)와 길이(L_1)인 2개 유닛, 출력층은 크랙이 있는 보의 처음 세 개의 고유진동수(f_1, f_2, f_3)인 3개 유닛, 패턴 수는 290개를 사용하였으며, 은닉층은 13개 유닛을 사용하였고 모멘텀 계수는 0.9, 적응학습률을 위한 에러율 0.001, 학습 증가율 1.05, 학습 감소율 0.7로 하였다. Fig. 7은 학습결과를 나타낸 것

이고 Fig. 8은 학습을 통해 출력값을 비교한 것이다.

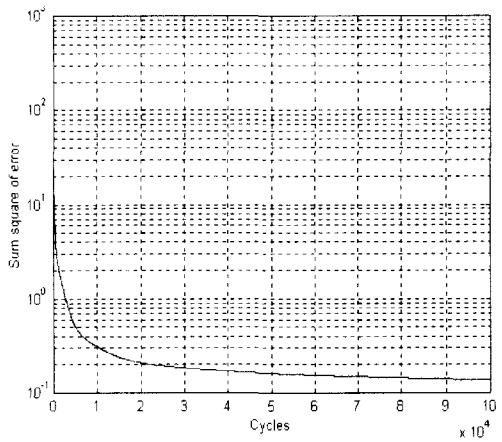


Fig. 7 Neural network training result

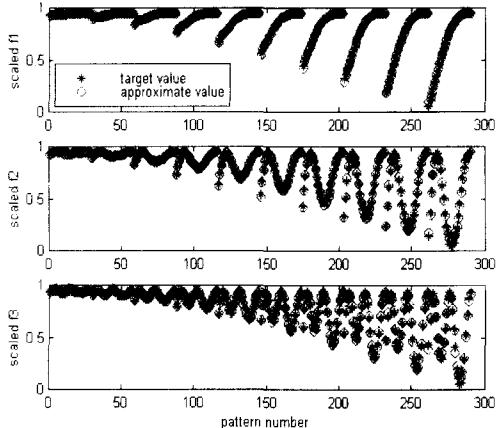


Fig. 8 Comparison target value with network output value

Fig. 7에서 알 수 있듯이 최종 SSE(Sum Square Error)은 0.13이고 출력값을 비교하였을 때 좋은 결과를 나타내었다. 이와 같이 구해진 네트워크를 유전자 알고리즘에 적용하여 크랙의 크기와 위치를 찾을 수 있는 최적화 문제를 구성하였다. 최적화 문제를 정식화하면 다음과 같다.

$$\begin{aligned} \text{Min } & (f_1 - f_1^*)^2 + (f_2 - f_2^*)^2 + (f_3 - f_3^*)^2 \\ \text{s.t. } & \alpha, L_1 \\ & 0.01 \leq \alpha \leq 0.1, \quad 0.1 \leq L_1 \leq 2.9 \end{aligned} \quad (18)$$

여기서 우리가 구하고자 하는 실제변수는 α . L_1 의 크랙의 깊이와 위치이고, α , L_1 에 해당하는 세 개의 고유진동수인 f_1 , f_2 , f_3 과 측정된 값 f_1^* , f_2^* , f_3^* 들과의 차이의 제곱의 합을 적합함수로 설정하였다. 세 개의 고유진동수인 f_1 , f_2 , f_3 를 구하기 위해 유전자 알고리즘을 적용하였고, 최대값을 구하는 문제로 변형하기 위해 적합도 함수를 식 (19)와 같이 설정하였다.

$$\text{fitness} = \frac{1}{\sum_{i=1}^3 (f_i - f_i^*)^2} \quad (19)$$

이때 모집단수(population size)는 150, 염색체의 길이는 25, 교배율은 0.25, 돌연변이 확률은 0.01. 선택방식은 Roulette Wheel Selection방식을 선택하였다. 해석 결과를 실험하기 위해 미리 알고 있는 두 군데 크랙의 깊이와 위치, 그리고 그 곳에서의 고유진동수를 가지고 위에 언급한 방법을 적용하였다. 첫 번째 크랙의 깊이와 위치는 각각 0.025m, 0.35m이며 이 때의 초기 세 개의 고유진동수 $f_1 = 112.29 \text{ rad/s}$, $f_2 = 714.03 \text{ rad/s}$, $f_3 = 2008.25 \text{ rad/s}$ 이다. 두 번째 크랙의 깊이와 위치는 0.065m, 1.05m이며 이 때의 초기 세 개의 고유진동수 $f_1 = 109.83 \text{ rad/s}$, $f_2 = 696.24 \text{ rad/s}$, $f_3 = 1910.72 \text{ rad/s}$ 이다. 이에 따른 적합함수의 수렴치를 Fig. 9, 10에 나타내었다.

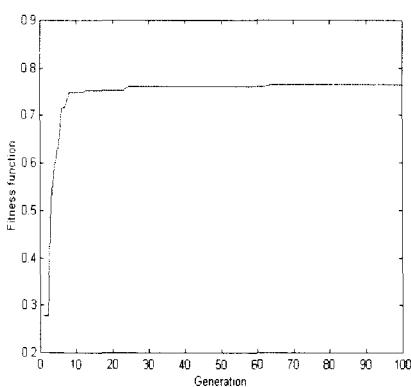


Fig. 9 Generation history of CASE I

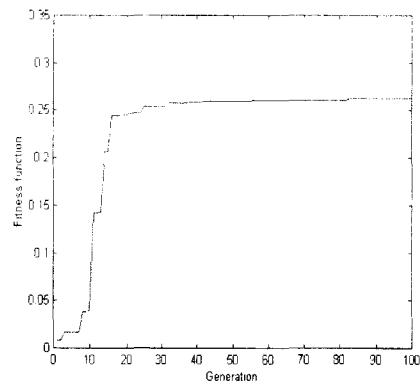


Fig. 10 Generation history of CASE II

Fig. 9에서 알 수 있듯이 66번째 세대에서 최적해가 나타나는 것을 볼 수 있었고 Fig. 10에서 알 수 있듯이 83번째 세대에서 최적해가 나타나는 것을 볼 수 있었다. 이때 크랙의 깊이와 위치는 Table 1에 나타내었다.

Table 1 Final analysis result

	CASE I		CASE II	
	Reference value	Result value	Reference value	Result value
α (m)	0.025	0.024	0.065	0.066
L_1 (m)	0.35	0.351	1.05	1.062
f_1 (rad/s)	112.29	113.19	109.83	110.05
f_2 (rad/s)	714.03	714.65	696.24	694.36
f_3 (rad/s)	2008.25	2007.91	1910.72	1911.15

Table 1에서 알 수 있듯이 두 경우 모두 좋은 결과를 나타내었으며 이로부터 인공신경망 이론과 유전자 알고리즘을 적용하여 크랙의 크기와 위치를 구하는 것이 효과적임을 알 수 있었다.

4. 결론

본 논문에서는 구조물내의 크랙의 크기와 위치

를 알아내기 위해 유한요소법을 이용하여 크랙의 크기 및 위치에 대한 서음 세 개의 고유진동수를 구하고 인공신경망의 학습을 통해 고유진동수를 이용하여 크랙의 크기와 위치를 구할 수 있는 역해석 문제를 정의하고 유전자 알고리즘을 이용하여 해를 구하였다. 이러한 접근 방법은 크랙의 크기 및 위치에 대한 고유진동수의 등고선을 그려서 등고선들 의 교점을 찾아내는 방법보다 정확하고 효과적일 뿐만 아니라 유전자 알고리즘을 이용하였기 때문에 다른 최적 알고리즘을 이용하여 해를 구한 것보다 국부 최소값에 빠지는 것을 방지할 수 있는 향상된 방법이라 할 수 있다.

후기

본 논문은 한국과학재단 산하 성균관대학교 산업설비 안전성평가 연구센터의 연구비 지원으로 이루어진 것으로서, 이에 관계자 여러분께 감사 드립니다.

참고문헌

1. T. C. Chondros and A. D. Dimarogonas, "Identification of cracks in circular plates welded at the contour." In: ASME Design Engineering Technical Conf., St. Louis, 1979.
2. T. C. Chondros and A. D. Dimarogonas, "Identification of cracks in welded joints of complex structures." J. Sound Vibr., Vol. 69, No. 4, pp. 531-538, 1980.
3. G. D. Gounaris and A. D. Dimarogonas, "A finite element of a cracked prismatic beam for structural analysis," Comput. Struct., Vol. 28, No. 3, pp. 309-313, 1988.
4. G. D. Gounaris and V. Papazoglou, "Three-dimensional effects on the natural vibration of cracked Timoshenko beams in water," Comput. Struct., Vol. 42, No. 5, pp. 769-779, 1992.
5. T. Inagaki, H. Kanki and K. Shiraki, "Transverse vibrations of a general cracked rotor bearing system," J. Mech. Des., Vol. 104, pp. 1-11, 1981.
6. P. S. Leung, "The effects of a transverse Crack on the dynamics of a circular shaft." In: Rotor dynamics '92. Int. Conf. on Rotating Machine Dynamics, Venice, 1992.
7. N. Anifantis, P. Rizos and A. D. Dimarogonas, "Identification of cracks on beams by vibration analysis." In: 11th Biennial ASME Conf. on Mechanical Vibration and Noise, Boston, 1987.
8. A. D. Dimarogonas and G. Massouras, "Torsional vibrations of a shaft with a circumferential crack," Engineering Fracture Mech., Vol. 15, pp. 439-444, 1981.
9. H. G. Nikolakopoulos, D. E. Katsareas and C. A. Papadopoulos, "Crack identification in frame structures," Computer & Structures, Vol. 64, No. 1, pp. 389-406, 1997.
10. T. Furukawa and G. Yagawa, "Parameter identification using an evolutionary algorithm and its performance under measurement errors," Computational Mechanics '95, Springer, pp. 122-127, 1995.
11. Rumelhart D. E., Hinton G. E. and Williams R. J., "Learning internal representations by error propagation," In Parallel distributed processing: exploration in the micro-structure of cognition, Vol. 1, pp. 318-362, 1986.
12. C. A. Papadopoulos and A. D. Dimarogonas, "Coupled longitudinal and bending vibrations of a cracked shaft," J. Vibr. Acoust. Stress Reliab. Des., Vol. 110, pp. 1-8, 1988.
13. H. Tada, The Stress Analysis of Cracks Handbook, Del Research Corporation, PA, 1973.
14. Mitsuo Gen, Runwei Cheng, Genetic algorithms and engineering design., A Wiley-Interscience Publication, 1997.