

통합적 인공지능 기법을 이용한 결함인식

심문보*·서명원**

Crack identification based on synthetic artificial intelligent technique

Mun-bo Shim, Myung-won Suh

Key Words: Crack identification(결함인식), Structure analysis(구조해석), Inverse analysis method(역해석 방법), Adaptive-Network-based Fuzzy Inference System(적응 네트워크 퍼지 추론시스템, ANFIS), Continuous Evolutionary Algorithm(진화 알고리즘, CEA)

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 synthetic artificial intelligent technique, that is, Adaptive-Network-based Fuzzy Inference System(ANFIS) solved via hybrid learning algorithm(the back-propagation gradient descent and the least-squares method) are used to learn the input(the location and depth of a crack)-output(the structural eigenfrequencies) relation of the structural system. With this ANFIS and a continuous evolutionary algorithm(CEA), it is possible to formulate the inverse problem. CEAs based on genetic algorithms work efficiently for continuous search space optimization problems like a parameter identification problem. With this ANFIS, CEAs are used to identify the crack location and depth minimizing the difference from the measured frequencies. We have tried this new idea on a simple beam structure and the results are promising.

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 파라메타라 할 수 있다. 결함진단을 위해서는 결함 유무, 결함 위치, 결함 정도를 파악해야하나 이는 매우 난해한 문제이다. 이를 해결하기 위해 현장실험을 통하여 얻은 측정자료와 수학적 모델을 이용하여 구

조물의 결함 위치 및 결함 정도를 파악하는 기술인 역해석 방법이 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 접근되어왔다. Chondros와 Dimarogonas^(1,2)는 크랙을 전체 구조물의 탄성에 영향을 주는 국부 탄성체(스프링)로 간주하였고 크랙의 깊이가 고유진동수의 감소와 관계한다고 주장했다. Gounaris와 Dimarogonas⁽³⁾은 특별히 크랙이 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

* 성균관대학교 대학원

** 성균관대학교 기계공학부

Inagaki⁽⁵⁾ 등은 고유진동수를 측정하여 크랙의 깊이와 위치를 알아내었고, Anifantis⁽⁶⁾ 등은 회전축의 동적거동을 측정하여 크랙을 인식하는 방법을 제안하였다. Nikolakopoulos et al.⁽⁷⁾ 는 크랙에 의해 발생된 구조물의 고유진동수 변화율을 측정하여 크랙의 깊이와 위치를 파악해 낼 수 있도록 고유진동수 변화율에 대한 크랙의 위치관계를 보여주는 등고선을 제안했다. 하지만 등고선 작성 및 교차점들을 찾기 위해서는 많은 시간과 노력이 필요하고 이를 인간의 눈을 통해 결정해야 하는 어려움이 있으므로 비효과적이다. 최근 결합인식을 위해 신경망이론을 이용한 방법들이 연구되었다.^(8,9,10,11) 이들 연구 대부분은 역해석 문제를 신경망이론을 통해 직접 해결하려고 노력하였고, 그 때문에 다양한 입,출력(특정FFT주파수대역-결합부위, 고유진동수/벡터-결합부위) 관계를 맺고 이를 인식했다. 하지만 역해석 문제를 직접적으로 신경망을 통해 해결하기 위해 너무 많은 입력들(200노드의 주파수 대역, 11개의 고유진동수와 11모드×28노드의 고유벡터{319의 입력노드},)을 사용하였고 on-line 상태에서 결합 인식을 하기에 부적합했으며 비싼 비용이 드는 문제가 있었다. 이를 해결하고자 신경망과 유전자 알고리즘을 결합한 결합인식법이 연구되었고 위의 어려움을 개선하였다.⁽¹²⁾ 하지만 신경망이론의 문제점 즉, 신경망 구성에 따른 변수선정(초기 weight 값, 은닉층 수, 은닉층 노드 수 등)의 어려움과 긴 학습시간 때문에 새로운 방법의 필요성을 느끼게 되었다.

본 연구에서는 유한요소법을 이용한 보 모델을 설립하고 크랙이 있는 구조물의 고유진동수를 구하여 적응 네트워크 퍼지 추론시스템(Adaptive Network Fuzzy Inference System)^(13,14)을 구성한 후 크랙을 인식하기 위한 역해석의 해를 구하기 위해 실수 탐색공간에서 매우 유용한 진화 알고리즘(CEA)^(15,16)을 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 미

지의 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 상태방정식을 이용하여 모델링을 세울 때 발생하게 되는 모델링 오차이다. 이와 같은 역해석 문제의 해를 구하는 방법은 실제로 많은 어려움이 있을 수 있다. 가령 함수의 관계가 일대일대응이 아니라면 역함수를 구하는 것은 불가능한 일이고 구한다 하더라도 잘못된 값을 구하게 된다. 이를 해결하기 위해 새롭게 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 (2)은 목적함수를 최소화하여 역해석 해를 구하기 위한 문제정의를 나타낸다.

$$\min f(x) \quad (2)$$

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

여기서, k_i 는 가중치이고 이와 같이 구성된 식을 최소화하여 이에 대응되는 매개변수 x 의 값을 구할 수 있다.

2.2 구조해석

평면 구조물은 3개의 자유도 ($\delta_x, \delta_y, \theta_z$)를 가진 2차원 보 요소를 이용하여 모델링할 수 있다. 구조물은 Euler-Bernoulli 이론으로부터 힘 평형 방정식과 변형의 기하학적 관계, 재료의 법칙을 이용하여 보 요소의 쪽 끝단의 상태변수와 반대 쪽 끝단의 상태변수관계를 나타내는 전달행렬(transfer matrix)이 계산되어진다.⁽⁷⁾




Fig. 1 A cracked beam finite element

Fig. 1은 끝단에서 거리 L_{1e} 만큼 떨어져 있고 깊이가 α 인 위치에 크랙을 가지고 있는 보 요소의 모습을 보여 주고 있다. 위치 i, C_L, C_R , 그리고 j 에서의 상태 벡터는 $\{z_i\}, \{z_L\}, \{z_R\}, \{z_j\}$ 으로 나타낼 수 있다.⁽⁷⁾ 여기서 i, j 는 보 요소의 양 끝단의 위치를 나타내며 R, L 은 크랙의 좌우위치, z 는 각 지점의 상태변수를 의미한다. 노드 i 와 j 사이에서 어떠한 힘도 작용하지 않는다면 식 (3a) ~ (3c)가 성립된다.

$$\{z_L\} = [T_1]\{z_i\} \quad (3a)$$

$$\{z_R\} = [T_c]\{z_L\} \quad (3b)$$

$$\{z_j\} = [T_2]\{z_R\} \quad (3c)$$

$[T_1]$ 과 $[T_2]$ 는 노드 C_L-i 와 C_R-j 사이의 관계를 나타내는 전달행렬이다. 그리고 $[T_c]$ 는 구조물 내에 존재하는 크랙의 두 점 C_L-C_R 의 관계를 나타내는 점 전달행렬(point transfer matrix)이다. 식 (3a) ~ (3c)부터 식 (4)이 얻어지고 식 (5)은 점 전달행렬을 나타낸다.

$$\{z_j\} = [T_c^*]\{z_i\} \quad (4)$$

$$[T_c^*] = \begin{bmatrix} 1 & 0 & 0 & c_{11} & 0 & c_{13} \\ 0 & 1 & 0 & 0 & c_{22} & 0 \\ 0 & 0 & 1 & c_{31} & 0 & c_{33} \\ 0 & 0 & 0 & -1 & 0 & 0 \\ 0 & 0 & 0 & 0 & -1 & 0 \\ 0 & 0 & 0 & 0 & 0 & -1 \end{bmatrix} \quad (5)$$

식 (5)에서 밑 첨자 1, 2 그리고 3은 인장, 전단, 그리고 굽힘을 의미한다. 여기서 c_{12} 과 c_{31} 항은 고려되지 않고 c_{11}, c_{22} 그리고 c_{33} 항이 고려된다.⁽¹⁷⁾ 크랙이 발생된 요소의 전달행렬은 식 (6)과 같다.

$$[T_c^*] = [T_2][T_c][T_1] = \begin{bmatrix} [A_1] & [A_2] \\ [A_3] & [A_4] \end{bmatrix} \quad (6)$$

여기서, $[A_1]$ 는 3×3 submatrices이다. 식 (7)은 크랙이 포함된 요소의 강성 행렬이다.

$$[K_c^*] = \begin{bmatrix} -[A_2]^{-1}[A_1] & [A_2]^{-1} \\ [A_3] - [A_4][A_2]^{-1}[A_1] & [A_4][A_2]^{-1} \end{bmatrix} \quad (7)$$

이로부터 크랙이 존재하는 구조물에 대한 운동 방정식을 행렬형태로 나타내면 식 (8)과 같고 이를 이용하여 고유 진동수를 구할 수 있다.⁽⁷⁾

$$-\omega^2[M] + [K] = \{0\} \quad (8)$$

2.3 결함인식을 위한 통합적 인공지능 기법

2.3.1 적응 네트워크 퍼지 추론시스템

적응 네트워크 퍼지 추론시스템은 신경망이론

과 퍼지시스템의 협력상승작용(synergism)의 한 형태이다. 다시 말해서 신경망이론과 퍼지시스템을 단일화하는 적응 네트워크로부터 출현하게 된 것이다. 적응 네트워크 퍼지 추론시스템은 모든 퍼지 추론시스템(Mandani형, Sugeno형, Tsukamoto형)을 구현할 수 있으나 본 연구에서는 1차 Sugeno 퍼지시스템과 등가인 시스템을 이용한다.

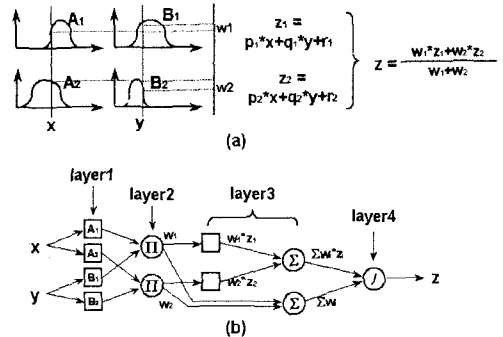


Fig. 2 (a) A two-input first-order Sugeno fuzzy model with two rules; (b) equivalent ANFIS

Fig 2.(a)는 1차 Sugeno 퍼지 추론시스템을 나타낸 것이고 이에 등가인 적응 네트워크 퍼지 추론시스템은 Fig 2.(b)에 나타내었다. 적응 네트워크 퍼지 추론시스템은 다음과 같이 층별로 계산된다.

1 층 : 이 층의 각 노드는 다음과 같이 정의되는 출력 노드를 갖는 적응 노드이다.

$$\begin{aligned} O_{1,i} &= \mu_{A_i}(x), \quad \text{for } i=1,2, \text{ or} \\ O_{1,i} &= \mu_{B_{i-2}}(y), \quad \text{for } i=3,4 \end{aligned} \quad (9)$$

여기서 $O_{1,i}$ 는 1 층의 i 번째 노드 출력을 의미하는 것이고 x (또는 y)는 노드 입력, A_i (또는 B_{i-2})는 노드에 관계된 퍼지 소속함수이다. 퍼지 소속함수의 예로 종형 함수는 다음과 같다.

$$\mu_{A_i}(x) = \frac{1}{1 + \left[\left(\frac{x - c_i}{a_i} \right)^2 \right]^{b_i}} \quad (10)$$

여기서 $\{a_i, b_i, c_i\}$ 는 전제부 변수들이다.

2 층 : 이 층의 각 노드는 입력 값들을 곱하는 고정된 노드이다. 예로

$$O_{2,i} = w_i = \mu_{A_i}(x) \times \mu_{B_i}(y), \quad i=1,2 \quad (11)$$

각 노드의 출력은 규칙부의 firing strength를 나타내고 규칙부는 grid partition에 의해 구성된다.

3 층 : 이 층의 각 노드는 노드 함수를 갖는

적응 노드이다.

$$O_{3,i} = \frac{w_i}{w_1 + w_2} (p_i x + q_i y + r_i) \quad (12)$$

여기서 $\frac{w_i}{w_1 + w_2}$ 는 정규화된 firing strength이고 $\{p_i, q_i, r_i\}$ 는 결론부 변수들이다.

4 층 : 이 층은 고정된 노드를 갖고며 출력은 모든 입력의 합으로 나타낸다.

$$O_{4,i} = \frac{\sum_i w_i z_i}{\sum_i w_i} \quad (13)$$

이와 같이 1차 Sugeno 퍼지시스템과 동일한 적응 네트워크 퍼지 추론시스템을 구성하였다. 이 시스템을 주의깊게 관찰해 보면 전제부의 변수와 결론부의 변수들이 아직 정해지지 않았다. 이 변수들을 구하기 위해 혼성 학습 알고리즘(hybrid learning algorithm)을 적용한다. Fig. 2를 보면 전제부의 변수가 고정되어 있을 때 최종적인 출력값들은 결론부의 변수를 포함한 선형방정식이 됨을 알 수 있다. 이들은 최소자승법(least-squares method)에 의해 결정된다. 또한 신경망이론 중 하나인 역전파 알고리즘과 같이 전제부의 변수들이 구배법(gradient descent)에 의해 구해진다.

이와 같은 적응 네트워크 퍼지 추론시스템은 혼성 학습 알고리즘에 의해 기존의 신경망 알고리즘보다 빠른 수렴속도 및 신경망 구성에 따른 변수선정(네트워크 초기값, 은닉층 수, 은닉층 노드 수 등)의 어려움이 없으며, 다른 퍼지 추론시스템에서의 가장 큰 어려움인 전문가적 지식(knowledge base)이 필요 없는 효과적인 방법이라 할 수 있다.

2.3.2 진화 알고리즘

진화 알고리즘은 자연진화의 모델에 기초를 둔 확률 최적화 알고리즘이다. 먼저, 실수 개체(individual)로 표현된 모집단(population)이 무작위로(random) 구성된다. (세대 t=0)

$$P^t = \{u_1^t, \dots, u_\lambda^t\} \in (R^n)^\lambda \quad (14)$$

여기서 R^n 는 개체의 차원을 나타내며, λ 는 집단 수를 의미한다. 실수로 표현된 개체들은 일반적으로 표현형(phenotype)이라 한다.

집단은 무작위 재결합(recombination)과 돌연변이(mutation), 선택(selection)을 통해서 탐색공간의 더 좋은 지역으로 진화한다. 재결합과 돌연변이

연산은 실수 범위에서 확률적인 분포에 의해 수행된다. 재결합의 경우 부모 세대들의 정보를 결합함으로써 자녀 세대를 구성하게 된다. 교배 연산은 다음과 같이 정의된다⁽¹⁶⁾.

$$\begin{cases} x_a^{t+1} = (1 - \mu_a^t) x_a^t + \mu_a^t x_\beta^t \\ x_\beta^{t+1} = \mu_\beta^t x_a^t + (1 - \mu_\beta^t) x_\beta^t \end{cases} \quad (15)$$

이를 비대칭 재결합(asymmetry recombination)이라 하며 여기서 x_a^t 와 x_β^t 는 세대 t에서의 부모 세대이고 μ_a^t 는 평균이 0이고 표준편차가 σ 인 정규분포이다.

$$\mu_i^t = N(0, \sigma^2) \quad (16)$$

표준편차는 자기적응전략(self-adaptive strategy)을 적용할 수도 있고 상수 값을 사용할 수도 있다. $\mu_i^t = \mu_j^t$ 인 경우를 대칭 재결합이라 하며 비대칭 교배와 비교하여 사용되는데, 대칭 재결합의 경우 문제의 성질이 단봉(unimodal)이거나 간단한 문제의 경우 빠른 수렴성을 보이지만 안정성이 떨어지는 반면 비대칭 재결합은 안정적인 탐색을 하기 때문에 본 연구에서는 비대칭 재결합을 사용하였다.⁽¹⁶⁾ 돌연변이 연산은 재결합에서 μ 값이 낮은 확률을 가지고 큰 값을 취하기 때문에 개체의 변화를 크게 할 수 있기 때문에 반드시 필요한 것은 아니지만 유전자 알고리즘과 같은 효과를 나타내기 위해 다음과 같이 간단히 표현할 수 있다.

$$x^{t+1} = rand(x_{min}, x_{max}) \quad (17)$$

2.3.3 결함인식을 위한 통합적 인공지능 기법

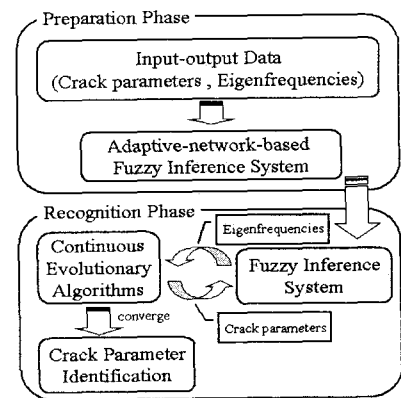


Fig. 3 Crack identification procedure on synthetic artificial intelligent technique

본 연구에서 결합인식을 위한 전반적인 순서는 Fig. 3에 나타나 있다. 여기에는 준비단계와 인식 단계로 구분된다. 먼저, 준비단계에서는 다양한 결합 변수들과 이에 해당하는 고유진동수들을 유한요소해석을 통해 추출한다. 그리고 이들을 이용하여 적응 네트워크 퍼지 추론시스템을 구성한다. 인식단계에서는 준비단계에서 구성된 퍼지 추론시스템을 진화알고리즘에 결합시켜 결합 변수를 추정할 수 있도록 역해석 문제로 정의하고 이를 구한다. 역해석 문제로 정의된 결합인식 문제의 정식화는 다음과 같이 나타낼 수 있다.

$$\min_{\alpha, L_1} F(\alpha, L_1) = \sum_{i=1}^3 (f_i - f_i^*)^2 \quad (18)$$

$$\alpha^{lower} \leq \alpha \leq \alpha^{upper}, L_1^{lower} \leq L_1 \leq L_1^{upper}$$

여기서 설계변수는 α, L_1 즉 크랙의 깊이와 위치이고, α, L_1 에 해당하는 세 개의 고유진동수인 f_i 과 측정된 값 f_i^* 이다. Fig. 4에서는 통합적 인공지능 기법의 적용순서를 나타내고 있다.

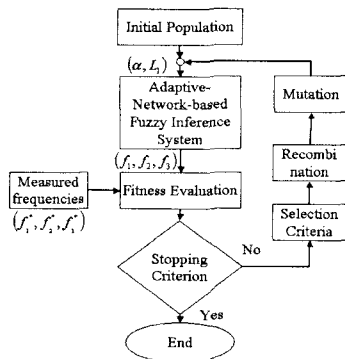


Fig. 4 Flowchart of the synthetic artificial intelligent technique

3. 수치해석 적용 및 결과




Fig. 5 Model of the cracked clamped-free beam

Fig. 5에 길이 $L = 3m$ 이고 단면이 $B \times H = 0.2m \times 0.2m$ 끝단에서부터 길이 L_1 만큼 거리가 떨어져있고 깊이 α 인 지점에 크랙을 포함하고 있는 clamped-free 보의 모습을 보여주고 있다. 이때, 재료 물성치는 $E = 2.07 \times 10^{11} Nm^{-2}$, $\nu = 0.3$ 그리고 $\rho = 7700 kgm^{-3}$ 이다.

먼저 크랙이 있는 경우의 강성행렬과 질량행렬을 적용하여 크랙의 깊이와 위치를 알 경우 그때의 고유진동수를 계산하고 이를 적응 네트워크 퍼지 추론시스템에 적용시켰다. 고유진동수의 계산을 위해 크랙의 깊이를 $0.01 \sim 0.1m$ 까지 10등분하였으며 크랙의 위치를 $0.1 \sim 2.9m$ 까지 29등분하였다. 적응 네트워크 퍼지 추론시스템에 적용하기 위해 입력은 크랙의 깊이(α)와 길이(L_1)로 하였고, 출력은 크랙이 있는 보의 처음 세 개의 고유진동수(f_1, f_2, f_3)에 대해 각각 분리하여 세 개의 추론시스템을 병렬로 구성하였다. 전체부의 퍼지 소속함수는 모두 일반화된 종형 함수를 사용하였고, 각 고유진동수에 따라 소속함수의 수는 $(\alpha, L_1) = (3,5), (3,14), (6,15)$ 를 사용하였다. 혼성 학습 알고리즘에 사용되는 구매법을 위해 적응학습률을 위한 에러율 0.01, 학습 증가율 1.1, 학습 감소율 0.9로 하였다. Fig. 6은 혼성 학습 알고리즘에 의해 퍼지 추론 시스템을 학습한 결과를 나타낸 것이고 Fig. 7은 추론을 통해 얻은 출력값과 해석값을 비교한 것이다.




Fig. 6 Hybrid learning result




Fig. 7 Comparison of the estimated eigenfrequencies to target values. (o target, * estimated value)

최종 RMSE(root mean square error)는 0.104이고, 반복 계산 횟수는 각각 50번이다. 이렇게 얻어진 퍼지 추론시스템을 통합적 인공지능 기법에 적용하여 결합인식을 수행하였다. 이때 진화알고리즘을 위해 모집단수(population size)는 50, 표준편차는 0.5, 돌연변이 확률은 0.01, 최대 반복횟수는 50, 선택방식은 Proportional Selection방식을 선택하였다. 해석 결과를 실험하기 위해 미리 알고 있는 두 군데 크랙의 깊이와 위치, 그리고 그 곳에서의 고유진동수를 가지고 위에 언급한 방법을 적용하였다. Fig. 8은 목적함수의 수렴치를 나타낸 것이고 Table 1은 실험결과이며 Table 2는 Hybrid neuro-genetic 기법⁽¹²⁾과 통합적 인공지능 기법의 방법론적 결과를 비교한 것이다.




Fig. 8 Generation history

Fig. 8에서 알 수 있듯이 7번째와 9번째 세대에서 최적해가 나타나는 것을 볼 수 있다. 이는 유전자 알고리즘과 진화 알고리즘의 수렴속도를 비교한 기존연구⁽¹⁵⁾의 결과와 마찬가지로 유전자 알고리즘으로 얻은 결과(Table 2)⁽¹⁶⁾에 비해 수렴도

가 빠른 것을 알 수 있다.

Table 1. Final analysis results

	Case (a)			Case (b)		
	Reference value	Result value	Relative Error(%)	Reference value	Result value	Relative Error(%)
α	0.02	0.02	3.8	0.065	0.062	4.3
L_1	0.3	0.3	0.152	1.05	1.058	0.84
f_1	113.48	113.35	0.11	109.83	110.45	0.57
f_2	714.46	714.23	0.031	696.24	697.12	0.12
f_3	2007.56	2007.62	0.003	1910.72	1909.97	0.039

Table 2. Comparison of Synthetic A.I. technique to Hybrid neuro-genetic technique

	Synthetic A.I. technique	Hybrid neuro-genetic technique	
	ANFIS	Back-Prop. NN	
Training Data	290	290	
RMSE	0.104	5.26	
Epoch Number	50×3	100,000	
		CEAs	GAs
		Case(a)	Case(b)
Generation No. of Optimal Sol.		7	9
		Case(a)	Case(b)
		84	47

Table 1에서 알 수 있듯이 두 경우 모두 좋은 인식결과를 얻었으며, Table 2로부터 통합적 인공지능기법을 이용하여 크랙의 크기와 위치를 구하는 것이 효과적임을 알 수 있었다.

4. 결론

본 논문에서는 구조물내의 크랙의 크기와 위치를 알아내기 위해 유한요소법을 이용하여 크랙의 크기 및 위치에 대한 처음 세 개의 고유진동수를 구하고 적응 네트워크 퍼지 추론시스템을 통해 고유진동수를 이용하여 크랙의 크기와 위치를 구할 수 있는 역해석 문제를 정의하고 실수 탐색공간에서 매우 유용한 진화 알고리즘을 이용하여 해를 구하였다. 이러한 접근 방법은 크랙의 크기 및 위치에 대한 고유진동수의 등고선을 그려서 등고선들의 교점을 찾아내는 방법보다 정확하고 효과적이며 국부 최소값에 빠지는 것을 방지할 수 있는 향상된 방법이라 할 수 있다. 또한 신경

망을 통해 해결하기 위해 너무 많은 입력 및 on-line 상태에서 결합 인식을 하기에 부적합하며 비싼 비용이 드는 문제를 해결하였고 신경망이론의 문제점을 적용 네트워크 퍼지 추론시스템으로 극복하였다.

후기

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

참고문헌

- (1) Chondros, T. C. and Dimarogonas, A. D., 1979, "Identification of Cracks in Circular Plates Welded at the Contour", In: ASME Design Engineering Technical Conference, St. Louis.
- (2) Chondros, T. C. and Dimarogonas, A. D., 1980, "Identification of cracks in welded joints of complex structures", Journal of Sound and Vibration, Vol. 69, No. 4, pp. 531-538.
- (3) Gounaris, G. D. and Dimarogonas, A. D., 1988, "A finite element of a cracked prismatic beam in structural analysis", Computer and Structure, Vol. 28, No. 3, pp. 309-313.
- (4) Gounaris, G. D. and Papazoglou, V., 1992, "Three-dimensional effects on the natural vibration of cracked Timoshenko beams in water", Computer and Structure, Vol. 42, No. 5, pp. 769-779
- (5) Inagaki, T., Kanki, H. and Shiraki, K., 1981, "Transverse vibrations of a general cracked rotor bearing system", Journal of Mechanical Design, Vol. 104, pp. 1-11.
- (6) Anifantis, N., Rizos P. and Dimarogonas, A. D., 1987, "Identification of cracks on beams by vibration analysis", In: 11th Biennial ASME Conference on Mechanical Vibration and Noise, Boston.
- (7) H. G. Nikolakopoulos, D. E. Katsareas and C. A. Papadopoulos, 1997, "Crack identification in frame structures," Computers & Structures, Vol. 64, No. 1, pp. 389-406, 1997.
- (8) X. Wu, J. Ghaboussi and J. H. Garrett, 1992, "Use of neural networks in detection of structural damage", Computers & Structures, Vol. 42, No. 4, pp. 649-659.
- (9) S. Kubo, 1993, Inverse Problem. Baifu-kan (in Japanese).
- (10) P. Tsou and M.-H. Herman Shen, 1994, "Structural damage detection and identification using neural network", AIAA Journal, Vol. 32, No. 1, pp. 176-183.
- (11) Q. Shi, I Hagiwara and T. Sekine, 1999, "Structural damage detection and identification using learning vector quantization neural network", Proceeding of the ASME design engineering technical conference.
- (12) M.-W. Suh, M.-B. Shim and M.-Y. Kim, 2000, "Crack identification using hybrid neuro-genetic technique", Journal of Sound and Vibration, 238(4), pp. 617-635.
- (13) Jang, J.-S. R., 1993, "ANFIS: Adaptive-network k-based fuzzy inference systems", IEEE Transactions on Systems, Man, and Cybernetics, Vol. 23, No. 3, pp. 665-685.
- (14) Jang, J.-S. R. and C.-T. Sun, 1995, "Neuro-fuzzy modeling and control", Proceedings of the IEEE.
- (15) Furukawa, T. and Yagawa, G., 1997, "Inelastic constitutive parameter identification using an evolutionary algorithm with continuous individuals", International journal for numerical methods in engineering, Vol. 40, pp 1071-1090.
- (16) M.-B. Shim, T. Furukawa, M.-W. Suh et al., 2000, "Efficient multi-point search algorithms for multiobjective optimization problem", Proceedings of Conference on Computational Engineering and Science, Vol. 5, No. 2, pp. 459-462.
- (17) Papadopoulos, C. A. and Dimarogonas, A. D., 1988, "Coupled longitudinal and bending vibrations of a cracked shaft", Journal of Vibration Acoustic Stress Reliability Design, Vol. 110, pp. 1-8.
- (18) Tada, H., 1973, The Stress Analysis of Cracks Handbook, Del Research Corporation. PA.