

論文

신경망 학습알고리즘의 비교와 2차원 익형의 비정상 공력하중 예측기법에 관한 연구

강승온*, 전상욱*, 박경현*, 전용희*, 이동호**

Study of Neural Network Training Algorithm Comparison and Prediction of Unsteady Aerodynamic Forces of 2D Airfoil

Seung-On Kang*, Sang-Ook Jun*, Kyung-Hyun Park*, Yong-Hee Jeon* and Dong-Ho Lee**

ABSTRACT

In this study, the ability of neural network in modeling and predicting of the unsteady aerodynamic force coefficients of 2D airfoil with the data obtained from Euler CFD code has been confirmed. Neural network models are constructed based on supervised training process using Levenberg-Marquardt algorithm, combining this into genetic algorithm, hybrid genetic algorithm and the efficiency of the two cases are analyzed and compared. It is shown that hybrid-genetic algorithm is more efficient for neural network of complex system and the predicted properties of the unsteady aerodynamic force coefficients of 2D airfoil by the neural network models are confirmed to be similar to that of the numerical results and verified as suitable representing reduced models.

초 록

본 연구에서는 오일러 CFD코드에서 얻은 데이터를 이용하여 2차원 익형의 비정상 공력하중을 모델링하고 예측할 수 있는 신경망의 능력을 확인하였다. 신경망 모델은 감독자 관리 학습을 기반으로 하여 르벤버그-마퀴트 알고리즘, 그리고 여기에 유전알고리즘을 결합시킨 혼합형 유전알고리즘을 사용하여 구성하고 각 경우에 대하여 그 효율성을 비교 분석하였다. 복잡한 시스템을 모사하는 신경망을 학습시키는 데는 혼합형 유전알고리즘이 더 효율적이라는 것을 보였으며 신경망모델에 의한 2차원 익형의 비정상공력하중 예측결과 실제 수치결과와 비교적 정확하게 일치하여 신경망 모델이 축소모델로서의 기능을 발휘하는 것을 입증하였다.

Key Words : Neural Network(신경망), Levenberg-Marquardt Algorithm(르벤버그-마퀴트 알고리즘), Hybrid Genetic Algorithm(혼합형 유전알고리즘), Unsteady Aerodynamic Force(비정상 공력하중), Reduced Model(축소모델)

1. 서 론

응용공기역학분야의 가장 큰 이슈 중 하나는 어떻게 하면 수치해석을 수행하는데 드는 방대한 계산시간과 계산비용을 줄이는가 하는 것이다. 이를 위하여 그림 1과 같이 전체모델에서 정보

† 2009년 3월 12일 접수 ~ 2009년 4월 28일 심사완료

* 정희원, 서울대학교 기계항공공학부 대학원

** 정희원, 서울대학교 기계항공공학부/항공우주신기술연구소
교신저자, E-mail : donghlee@snu.ac.kr
서울시 관악구 관악로 599번지

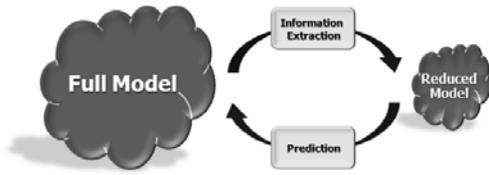


그림 1. 축소모델기법의 개념도

를 추출하여 축소모델을 만들고 이를 이용하여 전체모델을 예측하는 축소모델기법이 도입되었으며, 높은 정확도를 유지하면서 계산효율을 획기적으로 높이기 위한 연구가 활발하게 진행되고 있다.

대표적인 축소모델기법으로는 Volterra Series Representation (VSR), Proper Orthogonal Decomposition (POD), Harmonic Balance (HB) 와 같은 것들이 있으며, 그 밖에 신경망과 같은 근사모델을 이용하여 축소모델을 구성하기도 한다[1].

대표적인 근사모델 구성 방법으로는 반응면 기법 (Response Surface Method), 크리깅 기법 (Kriging Method), 신경망 기법 (Neural Network) 등이 있다. 기존 연구에 의하면[2] 반응면 기법은 다항식 형태의 함수모델을 이용하여 간단하게 근사모델을 구성할 수 있어 널리 사용되지만 비선형성의 모사능력이 떨어진다. 반면 크리깅 기법은 비선형성 모사는 우수하지만 신경망에 비해 효율적으로 반응값을 제시하지 못하는 것으로 알려져 있다. 따라서 본 연구에서는 비선형성 모사 능력이 뛰어나며 효율적으로 반응값을 보여주는 신경망을 이용하여 축소모델로서의 근사모델을 구성하였다. 즉, 기수내림과 기수올림이 있는 진동하는 2차원 익형의 비정상공력하중을 모델링하고 예측하는데 신경망 기법을 사용하였다.

신경망을 학습시키는 알고리즘은 다양하다[3]. 학습 알고리즘의 기본은 입력값이 주어질 때, 신경망의 출력 값과 목표 값의 차이를 최소화 하는 것이고 이 때, 신경망의 최적의 가중치 집합을 찾기 위해 경사도를 이용하는 것이 역전파 알고리즘(Backpropagation Algorithm)이다. 또한 가중치의 집합을 수렴시키기 위해서 다양한 최적화 알고리즘을 적용할 수 있는데 본 연구에서는 민감도정보를 이용한 르벤버그-마퀴트 알고리즘 (Levenberg-Marquardt Algorithm; LMA)과 유전 알고리즘(Genetic Algorithm; GA)을 이용하여 해를 최적점 근처에 갖다 놓은 후 LMA를 이용해 해를 최적점으로 수렴시키는 혼합형유전알고리즘

(Hybrid Genetic Algorithm; HGA)을 각각 적용하고 신경망의 학습방법으로서의 두 가지 알고리즘의 효율성을 비교 분석하였다.

따라서 본 연구에서는 신경망을 2차원 익형 주위의 비정상 유동 문제에 적용하여 공력하중계수들을 훨씬 적은 정보로도 비교적 정확하게 예측하는 것을 확인하였다. 또한 신경망모델 구축 후에는 원하는 유동조건에서의 공력하중을 예측하는데 더 이상의 공력해석을 필요로 하지 않는 것을 보여 축소모델로서의 효율성과 그 기능을 확인하였다. 또한 신경망 구성에 있어서 두 가지 대표적인 알고리즘을 비교 분석하여 복잡한 시스템을 모사하는 신경망을 구성하는 학습알고리즘으로서의 혼합형유전알고리즘이 더 효과적이라는 것을 입증하였다.

II. 이론적 배경

2.1 수치적 접근방법

응용공기역학 분야에서 에어포일의 주변의 유동과 같이 외부유동의 공력특성을 구할 때는 점성항을 무시한 오일러 방정식을 많이 이용한다. 2차원 비정상 압축성 오일러 방정식을 보존형으로 표현하면 식(1)과 같다.

$$\frac{1}{J} \frac{\partial Q}{\partial t} + \frac{\partial E}{\partial \xi} + \frac{\partial F}{\partial \eta} = 0 \quad (1)$$

공간 이산화 방법으로는 임의의 제어체적 (Control Volume)에 대하여 적분형 보존형 방정식(Integral Conservation Law)을 적용함으로써 물리적 변수들이 격자의 형태에 크게 구애받지 않는 유한 체적법(Finite Volume Method)을 사용하였으며, 격자경계를 출입하는 플럭스 항에 대해서는 풍상차분법(Upwind Difference Method)의 일종인 Roe의 플럭스분할기법(Roe's Flux Difference Scheme)을 사용하였다.

비정상 유동의 시간 계산을 위해서 James이 제안한 이중시간전진법(Dual Time Stepping)[4]을 사용하였으며 내재적(Implicit) 시간적분법인 LU-SGS(Lower-Upper Symmetric Gauss Seidel)를 사용하였다.

오일러 CFD코드[5]를 이용, 공력하중계수를 구하기 위하여 그림 2와 같이 진동하는 NACA0012의 공력중심(Aerodynamic Center)에서 점성항의 영향을 크게 받는 Cd를 제외하고 Cl과 Cm을 계산하였다. 진동하는 익형 문제에서는 받음각의 시간에 따른 변화를 외부에서 강제적으로 지정하게 되는데 이렇게 지정된 강제력의

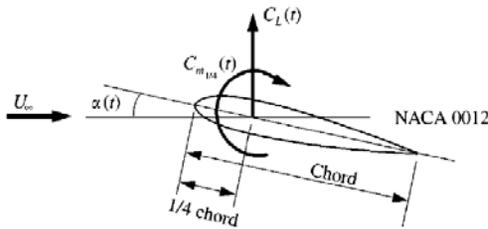


그림 2. 비정상 공력하중 계산을 위한 모델

진폭과 주파수에 따라서 익형의 받음각이 주기적으로 변하게 되며, 공력하중계수의 변화도 강제력과 비슷한 주파수를 가지면서 주기적인 양상을 나타낸다. 받음각을 사인파형태(Sinusoidal)로 기수올림과 기수내림의 변화를 주고 이에 따른 C_L 과 C_m 의 시간에 따른 변화를 살펴보았다. 이와 같은 사인파 형태의 입력 값은 헬리콥터 로터 블레이드와 같이 피치값이 일정한 주기를 가지고 변화하는 곳에 응용될 수 있다.

입력 값으로 사용된 마하수는 압축성효과가 나타나는 0.425~0.625범위에서 계산을 수행하였으며 k (reduced frequency; $\omega/2M_\infty$)값도 0.032~0.082범위에서 변화를 주었다[6].

2.2 신경망이론

신경망이론(Neural Network)[7]은 생체의 신경계가 정보를 처리하는 방식에서 착안, 이를 근사 모델구성에 적용한 것으로서 신경망모델은 학습 과정을 통해 새로운 환경에서의 적응성, 유연성, 잡음과 오차에 대한 견고성 등의 특징을 지니고 있다. 신경망에서는 뉴런(Neuron)이라는 기본 소자들이 신경세포와 같은 역할을 하며, 이 뉴런이 외부로부터 입력되는 정보를 전달받아 그 정보에 가중치를 곱하고 더한 다음 전달함수(Transfer Function)를 통해 다음 뉴런으로 전달된다. 뉴런의 정보 전달과정은 그림 3과 같으며, 수식으로 표현하면 식(2)와 같다. 여기에서 a 는 출력값 벡터, f 는 전달함수, R 은 입력값의 개수, ω 는 가중치, P 는 입력값 벡터, b 는 bias벡터를 의미한다.

또한 신경망에서는 기본 소자인 뉴런을 수직적으로 배열하여 층(Layer)을 구성하고, 여러 층을 수평적으로 겹침으로써 전체 네트워크를 구성한다. 본 연구에서 사용된 신경망은 입력층과 은닉층 사이에 식(3)과 같은 로그-시그모이드(Log-Sigmoid)함수를, 은닉층과 출력층 사이에 식(4)과 같은 선형함수를 전달함수로 갖는 3층 형태를 사용하였다. 여기에서 x 와 y 는 각각 전달함수의 입력 값과 출력 값을 의미한다.

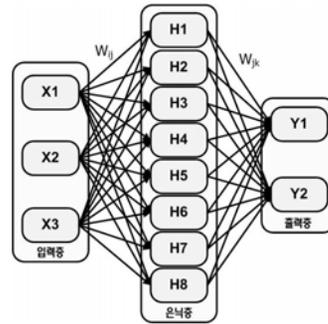


그림 3. 신경망의 개념도

$$a = f\left(\sum_{i=1}^{i=R} w_i P_i + b_1\right) \quad (2)$$

$$y = \frac{1}{e^{-x} + 1} \quad (3)$$

$$y = x \quad (4)$$

2.3 신경망 학습알고리즘

신경망의 가중치를 결정해주는 단계인 학습과정은 두 단계로 이루어진 역전파 알고리즘을 사용하였다. 첫째는 입력신호 값이 출력신호 값을 계산하기 위해 정보가 순방향으로 전달되는 것이고, 둘째는 각 층 사이의 가중치 값들이 실제 입력신호 값이 구성되는 모델의 출력신호 값과의 차이가 최소가 될 수 있도록 정보가 역방향으로 전달되는 것이다. 또한 초기 가중치 값들은 임의로 주고 학습시키는 과정을 여러 번 반복하여 실험점들의 모사 오차 제곱의 합이 최소로 되는 가중치들의 값을 결정하였다. 이때 각 뉴런을 연결하는 시냅스(Synapse)를 학습시키기 위해 최적화 기법이 사용되는데, 초기의 본 연구에서는 르벤버그-마퀴트 알고리즘, 유전알고리즘 그리고 혼합형유전알고리즘의 세 가지 최적화 알고리즘을 각각 적용하여 신경망 모델을 구성하였다. 하지만 유전알고리즘은 나머지 두 알고리즘에 비해 수렴시키기가 매우 어려워 비교 우위에 의해 비교 대상에서 제외시켰다.

2.3.1 르벤버그-마퀴트 알고리즘

르벤버그-마퀴트(Levenberg-Marquardt) 알고리즘은 뉴턴법(Newton's Method)의 변형된 형태로 다른 비선형함수들의 제곱합의 함수를 최소화하도록 고안된 알고리즘으로서 성능지수(Performance Index)는 오차제곱의 평균이고 신경망의 학습에 매우 좋은 성능을 보이는 것으로 알려져 있다. 이는 지역최적화 알고리즘으로서 민감도 정보와 수정된 헤시안행렬(Modified

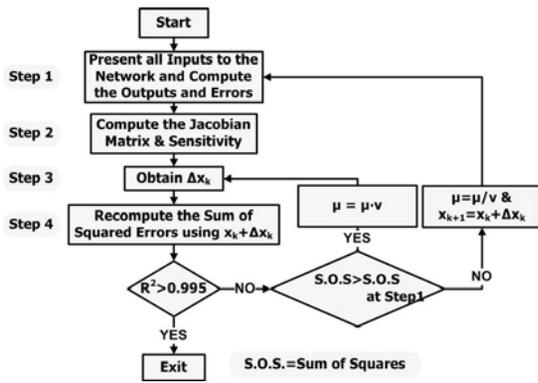


그림 4. 르벤버그-마퀴트 알고리즘을 이용한 신경망 모델링 과정

Hessian Matrix)을 이용해서 기울기가 감소하는 방향으로 연속적으로 움직이며 최적점을 찾아낸다. 따라서 국부최적점에 빠질 가능성이 있어 전역최적점을 찾는 데는 한계가 있다. 르벤버그-마퀴트 알고리즘을 이용한 신경망 모델링 과정을 그림 4에 나타냈으며 알고리즘에 대한 세부적인 내용은 참고문헌[7]에서 확인할 수 있다.

2.3.2 혼합형유전알고리즘

유전알고리즘은 교차와 변이 연산이 임의적으로 이루어지므로 국부최적점 근처에서 미세조정(Fine Tuning) 능력이 떨어지고, 민감도 정보를 이용하는 지역 최적화 알고리즘은 하나의 초기해에서 시작하므로 전역 최적점이 아닌 국부 최적점으로 수렴할 가능성이 높다. 이 두 가지의 단점을 상호 보완하기 위하여 지역 최적화 알고리즘이 유전알고리즘의 지역 최적점 근처에서의 미세조정을 돕고, 유전알고리즘이 지역최적화 알고리즘을 위한 다양한 초기해를 제공할 수 있도록 유전알고리즘으로 만들어진 해에 지역 최적화 알고리즘인 르벤버그-마퀴트 알고리즘을 결합하여 새로운 혼합형유전알고리즘(Hybrid Genetic Algorithm)[3,8]을 구성하였다. 본 연구에서는 유전알고리즘의 교배과정 및 탐색 후 무작위로 0~1사이의 Index값을 추출하여 0.9 이상이면 르벤버그-마퀴트 알고리즘을 수행하는 형식을 취하였다. 즉 유전알고리즘 반복계산 1회당 10% 확률로 지역최적화 알고리즘이 작동하게 된다[8]. 혼합형유전알고리즘을 이용한 신경망 모델링 과정을 그림 5에 나타내었으며, 마지막으로 두 가지 알고리즘이 각각 해를 찾아가는 과정을 그림 6에 비교하여 나타내었다.

이렇게 두 가지 알고리즘을 이용하여 공력하중 예측을 위한 신경망 모델 구성에 적용, 신경망의 학습 과정에서 최적가중치 집합을 구하는데 동일

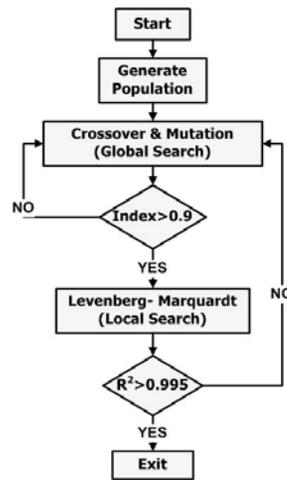


그림 5. 혼합형유전알고리즘을 이용한 신경망 모델링 과정

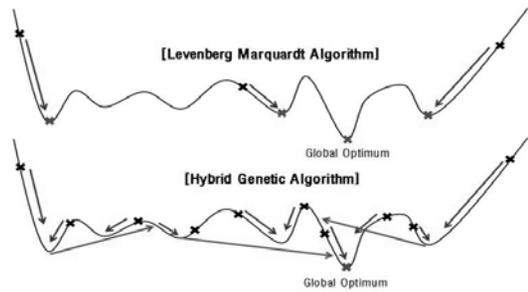


그림 6. 두 가지 알고리즘의 특징 비교

한 정확도를 기준으로 하여 필요한 함수의 호출 횟수, 계산시간을 비교하고 가장 효과적이 신경망 학습알고리즘에 대하여 논의할 것이다.

III. 결과 및 고찰

3.1 신경망을 이용한 공력하중 모델링

마하수, k(reduced frequency), 시간을 조합하여 표 1에서와 같이 총 25가지 경우에 대하여 오일러코드를 이용하여 CFD계산을 수행하였다. 사용한 pc의 제원은 CPU Pentium D 3.2 GHz, RAM 2GB이며 각 경우마다 0.01초의 시간 간격으로 3주기 이상 해석하여 초기의 오차 값들을 제거하기 위하여 700초까지 iteration을 총 70,000번을 수행하여 Cl과 Cm을 구한 결과 계산시간은 평균적으로 한 경우 당 약 33시간이 소요되었다. 만약 1대의 pc에서 차례대로 25가지 경우에 대하여 모든 계산을 수행한다면 약 825시간(약

표 1. CFD계산을 위한 실험점

	Ma	$k(\omega/2M_\infty)$	Time
1	0.425	0.0320	200 point
2	0.425	0.0445	200 point
3	0.425	0.0570	200 point
4	0.425	0.0695	200 point
5	0.425	0.0820	200 point
6	0.475	0.0320	200 point
7	0.475	0.0445	200 point
8	0.475	0.0570	200 point
9	0.475	0.0695	200 point
10	0.475	0.0820	200 point
11	0.525	0.0320	200 point
12	0.525	0.0445	200 point
13	0.525	0.0570	200 point
14	0.525	0.0695	200 point
15	0.525	0.0820	200 point
16	0.575	0.0320	200 point
17	0.575	0.0445	200 point
18	0.575	0.0570	200 point
19	0.575	0.0695	200 point
20	0.575	0.0820	200 point
21	0.625	0.0320	200 point
22	0.625	0.0445	200 point
23	0.625	0.0570	200 point
24	0.625	0.0695	200 point
25	0.625	0.0820	200 point
Total			5000 point

34일 9시간)이 소요된다. 그리고 25가지 경우 이외의 다른 유동조건에서의 결과 값을 알고 싶다면 해석을 위해 33시간의 추가적인 계산시간을 더 필요로 한다.

신경망을 구성하는데 필요한 입력 값으로는 마하수, k 그리고 시간을 사용하고, 은닉층의 뉴런 수는 적은 수에서부터 증가시키며 테스트 해본 결과 CI의 경우 5개가 가장 효율적으로 반응 값을 제시하였으며, Cm의 경우는 CI보다 좀 더 복잡한 형태의 공력특성이 나타나므로 은닉층의 뉴런의 수를 5개보다 약 3배 정도 많은 14개까지 사용하여야 원하는 정확도의 신경망모델을 구성할 수 있었다.

이미 해석이 끝난 각 결과에서 5000개의 실험점을 추출하였으므로 해석시간은 동일하게 소요되었다고 판단된다. 하지만 동일한 해석시간 후에 신경망모델 구축을 위해 실험점들을 가지고 신경망의 가중치조합을 학습시키는 데는 약 10분이 소요되어 해석에서부터 모델구성까지 약 825.2시간이 소요되었다. 하지만 일반적인 경우에는 향후에 다른 입력값에 대한 CI과 Cm을 계산하기 위해 한 경우마다 추가적인 33시간의 계산시간을 필요로 하는 반면 신경망모델을 통해 CI

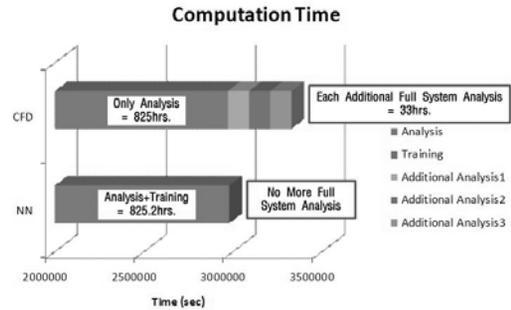


그림 7. CFD해석과 신경망의 계산시간 비교

과 Cm을 예측한다면 더 이상의 공력해석을 위한 계산 시간은 수 초에 불과하게 된다(그림 7). 즉, 마하수 0.425~0.625와 k값 0.032~0.082 범위 근처에서의 CI과 Cm은 더 이상의 전체모델의 해석 없이도 그 값을 예측할 수 있어 flutter 해석이나 설계문제의 적용에 있어 그 효율성을 향상시킬 수 있을 것으로 기대된다.

3.2 두 가지 학습알고리즘을 이용한 신경망 모델의 효율성

신경망모델 구성 시 각 뉴런을 연결하는 시냅스를 학습시키기 위해서 최적화 기법이 사용되는데, 본 연구에서는 르벤버그-마퀴트 알고리즘과 이 알고리즘을 유전알고리즘과 결합시킨 혼합형 유전알고리즘을 사용하여 CI과 Cm에 대한 신경망 모델을 각각 구성하였다. 이때 수렴조건으로는 신경망 모델의 R²값이 CI은 0.999이상, Cm은 0.995이상 이 되도록 부가하였다. 두 가지 경우에 차이를 둔 것은 Cm의 공력특성이 CI보다 복잡하게 나타나 Cm의 R²값을 0.996이상으로 높이는 것이 어려웠기 때문이다. 하지만 일반적으로 R² 값이 0.99 이상이면 구성된 신경망 모델의 적합도나 신뢰도가 충분히 확보되었다고 판단한다. 본 연구에서는 신경망 모델이 좀 더 높은 신뢰도를 가질 수 있도록 각 경우에 대해서 R²값이 최대가 되도록 설정하였다.

표 2에서는 르벤버그-마퀴트 알고리즘과 혼합형 유전알고리즘의 효율성을 비교하기 위해 함수 호출회수와 계산시간을 비교하였다. CI의 경우 사인곡선 형태의 매우 규칙적이고 간단한 공력특성을 나타내므로 신경망모델을 구성하는데 르벤버그-마퀴트 알고리즘이나 혼합형 유전알고리즘이 모두 수초 내에 수렴하여 계산시간에 있어서 두 알고리즘의 효율성을 비교하는 것이 큰 의미가 없다. 또한 함수 호출회수에서 혼합형 유전알

표 2. 두 가지 학습알고리즘의 효율성 비교

	LM		Hybrid Genetic	
	CI	Cm	CI	Cm
Hidden Node	5	14	5	14
R ²	0.9991	0.9950	0.9994	0.9951
Function Call	108	626	192	286
Computation Time (sec)	6.1	236.8	8.75	94.1

고리즘의 특성상 계산 초기에 함수 호출 횟수가 증가하게 되어 간단한 시스템의 모사에는 오히려 비효율적일 수 있다. 하지만 Cm과 같이 시간에 따라 매우 불규칙적인 형태를 보이고 이를 신경망모델로 구성하는 데도 CI에 비해 약 3배정도의 뉴런수를 필요로 하며 수렴시키는데도 수십에서 수백초가 소요되는 경우는, 계산시간과 함수호출 회수에서 효율적인 알고리즘이 보다 큰 강점을 갖게 된다. 표 2를 통해 복잡한 Cm의 공력특성을 모사하는데 르벤버그-마퀴트 알고리즘에 비해 혼합형 유전알고리즘의 함수호출회수가 약 54%가 적으며 계산 시간도 약 60%가 적게 걸리는 것을 확인할 수 있다. 즉 단순한 시스템을 신경망모델로 구성할 때는 르벤버그-마퀴트 알고리즘이 장점을 갖지만 복잡한 형태의 시스템에 있어서는 혼합형 유전알고리즘이 큰 효율성 보이는 것으로 사료된다.

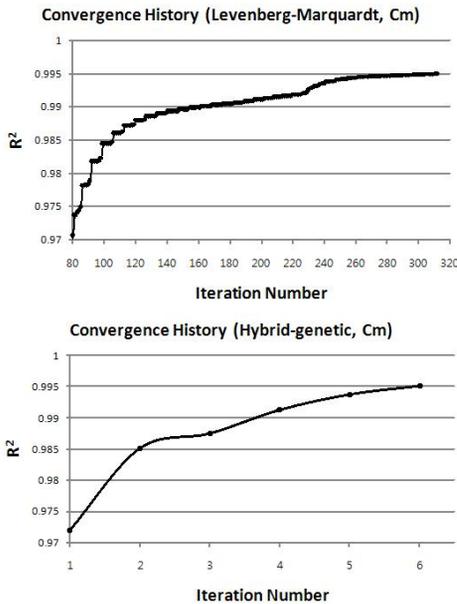


그림 8. 알고리즘에 따른 R²값의 수렴과정

그림 8에서는 두 알고리즘으로 Cm의 신경망 모델 구성 시 R²값의 수렴되는 과정을 그래프로 나타내었다. 르벤버그-마퀴트 알고리즘의 경우는 약 310회의 반복계산을 수행해야 수렴하지만 혼합형 유전알고리즘은 단 6회의 반복계산으로 수렴하는 것을 확인할 수 있다.

따라서 복잡한 시스템을 신경망으로 모사할 때의 학습알고리즘으로는 함수호출회수와 계산시간 그리고 반복계산 회수를 비교해 보았을 때 단순히 민감도 정보만을 기반으로 하는 지역 최적화 알고리즘보다는 지역 최적화 알고리즘이 유전알고리즘의 미세조정을 돕고, 유전알고리즘이 지역최적화 알고리즘을 위한 다양한 초기해를 제공하는 혼합형 유전알고리즘이 더 효율적이라고 판단된다.

3.3 신경망을 통한 공력하중 모사

NACA0012의 받음각을 sinusoidal 형태로 변화를 주고 시간에 따른 CI와 Cm의 형태를 나타내었다. 그림 9는 신경망 구성을 위해 추출한 실험점의 조건중 하나인 마하수가 0.525이고 k값이 0.0695일 때, 각각 르벤버그-마퀴트 알고리즘과 혼합형 유전알고리즘을 이용하여 구성된 신경망 모델로 시간에 따른 진동하는 익형의 공력하중계수의 변화를 나타낸 그래프이다. 첫 번째 그래프는 받음각의 변화를 나타내고, 두 번째 그래프는 CI의 변화 그리고 세 번째 그래프는 공력중심에서의 Cm의 변화를 나타낸다. R²값이 0.995이상이고 실험점 조건에서의 CI와 Cm의 추이를 모사한 것이므로 르벤버그-마퀴트 알고리즘과 혼합형 유전알고리즘 모두 시간에 따른 공력하중을 비교적 정확하게 모사하고 있다는 것을 확인할 수 있다. 알고리즘에 따라 신경망 모델의 예측값이 약간의 차이를 보이는 것은 동일한 정확도를 가지더라도 신경망을 구성하는 시냅스(가중치)는 다양한 값을 가질 수 있기 때문이다.

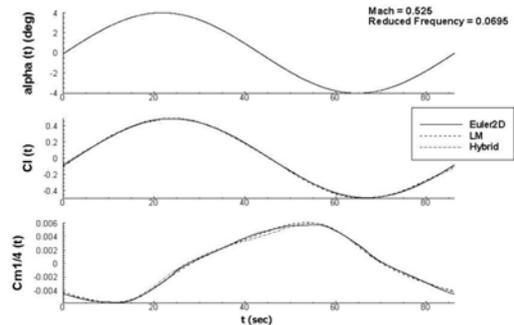


그림 9. M=0.525, k=0.0695일 때의 비정상 공력하중모사

3.4 신경망을 통한 공력하중 예측

마지막으로 신경망이 축소모델로서의 기능을 발휘하는가를 입증하기 위해 신경망 구성을 위해 추출한 실험점의 조건이 아닌 주어진 영역(Ma: 0.420~0.625, k: 0.032~0.082) 내의 임의의 새로운 입력 값에 대한 공력하중계수를 예측한 결과를 그림 10에서부터 그림 13까지 나타내었다. 이때의 유동조건 값들과 error값을 표 3에 정리하였으며 error값은 식(5)로 계산한 결과 모두 1.2E-04이하로 매우 신뢰할만한 결과를 보여준다. 그림 10~그림 13의 그래프들은 모두 비정상 공력하중계수를 추가적인 CFD계산을 통해서가 아닌 신경망모델을 통해서 예측한 결과이다. 여기서는 르벤버그-마퀴트 알고리즘과 혼합형유전알고리즘으로 구성된 각각의 신경망으로 예측한 비정상 공력하중계수를 비교해 보면 가중치 값의 다양한 해집합으로 인한 신경망 모델의 예측값이 미소한 차이를 보이는 것을 확인할 수 있다. 또한 일부 그래프에서 smoothing현상이 나타나는데 이는 신경망 모델의 학습과정을 통하면 예측 모델이 실험점에 대하여 근사화가 되기 때문이다. 따라서 특정한 유동조건에 대해서 smoothing이 발생하는 것이 아니라 신경망 모델 자체의 특성으로 인해 smoothing이 발생하는 경우가 생긴다. 하지만 두 가지 알고리즘으로 학습시킨 신경망모델 모두 비교적 정확하게 비정상 공력하중계수의 추이를 예측하는 것을 확인할 수 있으며 충분히 flutter 해석이나 설계문제에 적용시킬 수 있을 것으로 판단된다. 결론적으로 추가적인 공력해석 없이 기존의 데이터만을 가지고 신경망모

델을 통해 새로운 유동조건에서의 공력하중을 예측할 수 있는 축소모델로서의 가능성을 확인하였다.

$$Error = \frac{\sqrt{\sum (y_i - \hat{y}_i)^2}}{N} \quad (5)$$

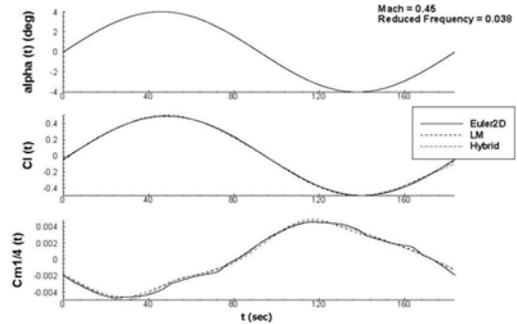


그림 10. M=0.45, k=0.038일 때의 비정상 공력하중예측

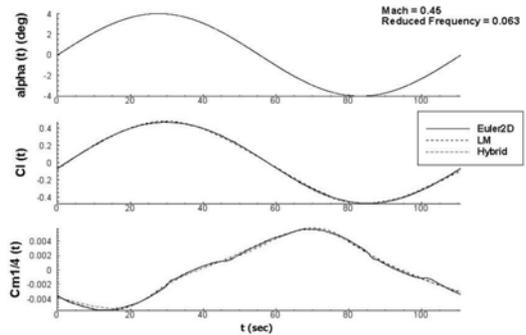


그림 11. M=0.45, k=0.063일 때의 비정상 공력하중예측

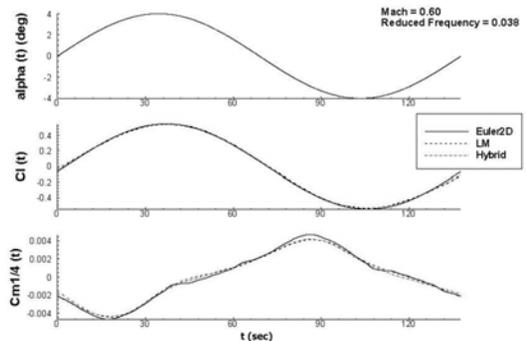


그림 12. M=0.60, k=0.038일 때의 비정상 공력하중예측

표 3. 유동조건과 공력하중예측 오차

	Ma	k	Coeff	Algorithm	Error
그림 10.	0.45	0.038	Cl	LM	7.0E-05
				Hybrid	4.9E-05
			Cm	LM	1.8E-06
				Hybrid	1.5E-06
그림 11.	0.45	0.063	Cl	LM	8.3E-05
				Hybrid	6.6E-05
			Cm	LM	1.5E-06
				Hybrid	1.9E-06
그림 12.	0.60	0.038	Cl	LM	1.2E-04
				Hybrid	9.4E-05
			Cm	LM	2.1E-06
				Hybrid	1.9E-06
그림 13.	0.60	0.063	Cl	LM	1.0E-04
				Hybrid	6.6E-05
			Cm	LM	2.0E-06
				Hybrid	2.0E-06

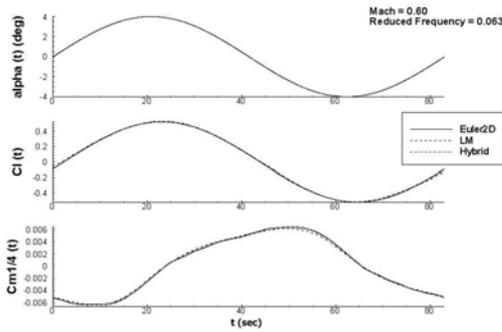


그림 13. $M=0.60$, $k=0.063$ 일 때의 비정상 공력하중예측

IV. 결 론

본 연구에서는 다양한 유동조건에서의 2차원 익형 주위의 비정상 공력하중정보를 가지고 두 가지의 학습알고리즘을 이용하여 신경망모델을 구성하였고, 다음과 같은 세 가지 결론을 도출하였다.

첫째, 신경망모델을 복잡하고 시간이 오래 걸리는 비정상 CFD계산에 응용하면 계산시간과 계산비용을 획기적으로 줄일 수 있다는 것을 확인하였다. 이를 flutter 해석이나 설계문제 flow control에 적용할 경우 해석 및 설계 효율을 상당히 향상시킬 수 있을 것으로 기대된다.

둘째, 복잡한 시스템을 모사하는 신경망의 학습알고리즘으로는 민감도 정보를 기반으로 하는 지역 최적화알고리즘보다는 이것을 유전알고리즘과 결합한 혼합형유전알고리즘이 함수호출회수와 계산시간의 기준에서 효율적이라는 것을 확인하였다.

마지막으로 신경망으로 구성된 모델들이 실험점 조건에서의 공력하중을 비교적 정확하게 모사할 수 있을 뿐만 아니라 실험점 조건 이외의 새로운 유동 조건에서도 더 이상의 추가적인 공력 해석 없이 신경망 모델을 통해 공력하중 예측이 가능하다는 것을 보였다. 따라서 신경망모델은 CFD분야에서 높은 예측 정확도를 유지하면서 계산 시간을 확연히 줄여주는 축소모델(Reduced Model)로서의 기능을 발휘할 수 있을 것으로 사료된다.

후 기

본 연구는 교육과학기술부의 BK21 사업(차세대 기계항공시스템 창의설계 인력양성사업단),

방위사업청과 국방과학연구소의 지원으로 수행되었습니다(계약번호 UD070041AD).

참고문헌

- 1) David J. Luciaa, Philip S. Beranb, Walter A. Silvac, "Reduced-order modeling: new approaches for computational physics", Progress in Aerospace Sciences, 40, 51-117, 2004.
- 2) 전상욱, 전용희, 김정화, 이동호, "항공기 날개 설계를 위한 강건성 및 신뢰성 최적 설계 기법의 적용", 한국항공우주학회지, 제34권 제8호, pp. 24-32, 2006.
- 3) 김정환, "유전 탐색에서의 인공신경망 재조각화", 서울대학교 박사 학위 논문, 2006.
- 4) 이보성, 이관중, 주완돈, 이동호, "앞전 Droop과 Gurney 플랩을 이용한 동적 실속 제어", 한국항공우주학회지, 제32권 5호, 2004.
- 5) 주완돈, 이관중, 이보성, 이동호 "두께 변화를 통한 동적실속연구", 한국항공우주학회지, 제28권 3호, 2000.
- 6) F.D. Marques, J Anderson, "Identification and Prediction of Unsteady Transonic Aerodynamic Loads by Multi-Layer Functions", Journal of Fluids and Structures, 15, 83-106, 2001.
- 7) Martin T. Hagan, Howard B. Demuth, Mark H. Beale, "Neural Network Design", PWS Publishing Company, 1996.
- 8) 문병로, "유전알고리즘," 두양사, 2005.
- 9) F.D. Marques, J Anderson, "Modelling and identification of non-linear unsteady aerodynamic loads by neural networks and genetic algorithms", ICAS Paper 96-7.1.1, September 1996.
- 10) Dilek Funda Kurtulus, "Ability to forecast unsteady aerodynamic forces of flapping airfoils by artificial neural network", Neural Comput & Applic, April 2008.
- 11) 김연경, "신경망이론을 이용한 항공기 개념설계에 관한 연구", 서울대학교 석사 학위 논문, 2002.
- 12) David E. Goldberg, "Genetic Algorithms in Search, Optimization, and Machine Learning", Qeeiwon-Wesley, 1989.
- 13) James A. Freeman, David M. Skapura, "Neural Networks - Algorithm, Applications, and Programming Techniques", Addison-Wesley, 1992.
- 14) Nixon, D. "Unsteady transonic aerodynamics", Progress in Astronautics and Aeronautics, Vol. 120. Washington: AIAA, 1989.