

'95 춘계학술발표회 논문집
한국원자력학회

신경망 기법을 사용한 구조계의 미지계수추정

방 은영, 윤 정방

한국과학기술원

요 약

구조물의 미지구조계수를 추정하기 위한 방법으로 신경망이론을 사용하였다. 다층퍼셉트론과 Gaussian Basis Function Network의 장점을 살리기 위해, 복합신경망을 제안하였으며, 제안된 신경망이 학습시 수렴속도가 향상되고, 적절한 분할확대의 수를 결정하면 일반화 성능도 유지할 수 있음을 확인하였다. 전단건물모형에 대하여 구조계수추정의 절차를 설명하였으며, 제안된 신경망의 효율성을 보이었다.

1. 서 론

구조물의 손상도추정이나 안전진단을 위해서 구조계수를 추정하는 기존의 방법은 Extended Kalman Filter 방법, 순차적예측오차방법, 모우드섭동법, 민감도방법 등이 있다. 이러한 방법들은 운동방정식이나 모우드관계식과 같이 구조물을 대표하는 식을 이용하는 알고리즘이므로, 시간이 적게 소요되어 효율적이고 다양한 문제에 좋은 결과를 주었다. 그러나, 구조물 관계식에 의존도가 높아서, 구조물의 관계식이 복잡한 다자유도 문제에 적용하기 어려운 단점이 있다.

이에 반하여, 본논문에서 제안한, 신경망에 의한 방법은 학습데이터 계산과 학습에 많은 시간이 소요되지만, 일단 학습된 신경망은 그 결과에 대하여 안정성을 보장하므로 사용시에는 안정적으로 사용할 수 있고, 간단한 연산을 통하여 결과를 출력하기 때문에 사용단계에서의 출력시간은 적게 소요된다. 또한 학습데이터로 사용가능한 입력자료 선택의 폭이 넓다. 예를 들어 동적자료로는 자유진동수와 자유진동모우드 및 정적자료로는 정적변위 등을 사용하기에 용이하다. 신경망이론의

근본적인 관점이 구조물 관계식에 의존하는 것이 아니라, 구조물을 대표하는 학습데이터에 의존하는 알고리즘이므로 구조물의 관계식이 복잡한 문제에 대하여 적용할 때 장점이 부각된다.

2. 복합 신경망(Hybrid Neural Network)

함수근사의 목적으로 사용하는 신경망모델에는 다충퍼셉트론과 Gaussian Basis Function Network(GBFN) 등이 있다. 다충퍼셉트론은 필요한 연결강도의 수는 GBN보다 적지만, 학습시 수렴속도가 느려서 많은 시간이 요구되고, GBN은 은닉뉴런들이 각각 특정 입력공간에 대하여 반응하는 지역성이 뚜렷하므로 학습시 수렴속도가 빠르다. 그러나 입력공간의 차원이 커짐에 따라서 은닉뉴런의 수가 지수함수적으로 증가하여 입력공간이 큰 문제에는 적합하지 않다.

두 신경망의 장점을 살리면서 일반화 성능도 좋은 신경망을 위해 그림1.(d)와 같은 형태의 구조를 갖는 신경망을 제안하였다. 즉, 각 입력유니트마다 식(1)과 같이 가우시언 함수를 사용하여 분할변환하여 입력공간을 Cover의 정리가 언급하듯이, 입력공간이 확대되면 학습이 쉬운 사실을 주목한다면 제안된 방법은 수렴속도가 증가함을 예상할 수 있다.

입력공간을 분할변환할 때 가우시언 함수의 각 중심은 입력공간의 정의역에 균일하게 분할하고 표준편차는 일반화성능을 고려하여 결정한다. 표준편차를 신경망의 연결강도처럼 조정되어야 할 파라미터로 간주하면, Overtraining이 발생하여 일반화 성능이 저하될 수 있으므로, 일반적으로 GBN에서 사용하는 식(2)를 따른다.

$$\varphi_i(x) = \exp\left(-\frac{\|x - t_i\|^2}{2\sigma^2}\right), i = 1, 2, \dots, M \quad (1)$$

$$\sigma = \frac{d}{\sqrt{2M}} \quad (2)$$

여기서, d 는 중심사이의 최대거리, M 은 각 입력유니트 당 분할된 유니트의 갯수(=LO), σ 는 분할변환을 위해 사용된 가우시언 함수의 표준편차, t_i 는 분할된 i 번째 뉴런의 중심좌표이다.

3. 미지구조계수 추정

3.1 신경망을 사용한 구조계수추정의 절차

그림2에 신경망을 사용하여 구조계수를 추정하는 절차를 도시하였다. 학습단계에서는 알고자하는 구조계수 θ 를 변화시켜가며, 구조해석을 수행하여 하중 $x(t)$ 와 응답 $y(t)$ 으로 구성된 다수의 데이터를 구한다. 이때, 데이터의 수는 구조물을 충분히 대표할 만큼 많아야 한다. 이와같이 구해진 데이터를

신경망의 입력에 적합하게 처리한 다음, 처리된 데이터 $T\{x(t),y(t)\}$ 를 신경망의 입력으로 사용하였을 때 해당하는 구조계수 θ 가 출력되도록, 학습을 수행하여 신경망의 연결강도(W)를 결정한다(그림2.a). 사용단계에서는, 학습완료된 신경망은 대상구조물에 실험을 수행하여 계측한 자료 $x(t)$, $y(t)$ 를 학습된 신경망에 적합하게 변환($T\{x(t),y(t)\}$)하여 신경망에 입력하면, 그 입력에 해당하는 결과를 출력한다(그림2.b).

3.2 자유진동특성치를 사용한 구조계수추정

그림3과 같은 전단건물모형의 구조계수를 추정하는 예를 통하여 제안된 신경망모델의 타당성을 검증하고, 신경망을 통한 구조계수추정 절차를 보이고자 한다.

입력데이터로 자유진동수를 사용하여 구조계수를 추정하는 과정을 소개한다. 그림 3의 구조물에서 k_4, k_6, k_8 의 부재강성을 미지구조계수라고 가정하고 나머지 구조계수는 표 1과 같이 기지의 값으로 가정하였다. 구조물의 저차 자유진동수 3개를 신경망의 입력에 해당하는 자료로 정하였다. 학습데이터를 구하기 위해 표1과 같이 3개의 미지 강성이 200~400사이에 있다고 가정하여, 200, 250, 300, 350, 400 과 같이 각각 50의 간격 분해하면 3개의 미지수이므로, 125개의 경우의 수가 있을 수 있다. 각 경우에 대하여 고유치해석을 수행하여 3개의 저차 진동수를 구했다. 시험데이터는 225~375의 범위를 갖고 역시 50의 간격으로 분해하여 64개의 고유치해석을 수행하였다. 이와같은 가정을 바탕으로 학습데이터와 시험데이터를 구한결과를 표2에 나타내었다.

신경망 모델을 비교하기 위해 그림1과 같은 4개의 신경망구조에 대하여 표2와 같이 여러경우에 대하여 학습을 수행하여, 학습오차와 학습중 시험오차의 변화과정을 그림 4 에 나타내었다. 그림 4(a)와 같이 학습오차는 제안된 복합신경망이 가장 좋은 수렴성을 보이고 있다. 다른 모델들은 그림중에 평탄한 부분이 나타남을 발견할 수 있다. 이와같은 현상은 그 부분에서 지역오차에 빠진 것이거나, 연결강도가 오차곡면의 평탄한 지역에 있는 경우이다. 제안된 모델은 그러한 부분이 없이 부드럽게 오차가 감소하고 있다.

분할영역의 수(LO)의 영향을 관찰하기 위해, LO가 각각 3과 5인 경우를 그림 5 에 비교하였다. 두 경우의 학습오차(그림 5.a)의 감소형태는 비슷하지만 시험오차(그림 5.b)는 오히려 LO=5인 경우가 크다. 이 문제의 경우에 LO=3인 경우가 최적의 신경망 크기에 가깝다는 의미이다. 결론적으로, 표3에 LO=3 인 복합신경망을 학습한 후, 시험데이터에 대한 결과를 나타내었다. 평균상대오차 1.5%로 만족할 만한 결과를 보이고 있다.

4. 결론

제안된 복합신경망이 연결강도의 수가 비슷한 구조를 갖는 다른 모델에 비하여 수렴속도가 향상된 것을 확인 할 수 있었다. 그 주된 이유는 가우시언 함수를 사용한 입력공간의 분할로 야기된 입력유니트의 지역화(Localization)이다. 대상문제가 복잡할수록 분할확대의 수(LO)가 커지고, 단순한 문제는 작은 분할로도 목적을 달성할 수 있음을 알 수 있다. 분할확대 수가 커지면 학습수렴속도는 증가하지만 일반화성능은 감소하므로 문제마다 적절하게 결정하여야 한다.

표 1 구조물의 질량과 강성

자유도	1	2	3	4	5	6	7	8	9	10
질량	10	10	10	12	12	12	15	15	15	15
강성도	300	300	300	200~400	400	200~400	400	200~400	400	400

표 2 학습에 사용된 데이터

	입력벡터	출력벡터
학습 데이터	[1] 120.7 103.6 94.2	400 400 400
	[2] 120.6 102.9 90.9	400 400 350

	[124] 103.2 89.2 80.6	200 200 250
	[125] 103.2 88.8 77.5	200 200 200
시험 데이터	[1] 117.3 102.3 92.2	375 375 375
	[2] 117.2 101.8 88.7	375 375 325

	[63] 104.0 92.1 82.6	225 225 275
	[64] 104.0 91.7 79.2	225 225 225

표 3 학습완료후 시험결과 (LO=3)

패턴	입력/출력/참값/상대오차
1	INPUT: 117.3 102.3 92.2 OUTPUT: 381.0 375.5 377.2 TRUE: 375.0 375.0 375.0 ERROR: 1.6% 0.2% 0.6%
25	INPUT: 109.8 98.5 91.4 OUTPUT: 327.1 274.4 377.8 TRUE: 325.0 275.0 375.0 ERROR: 0.7% 0.2% 0.8%
64	INPUT: 104.0 91.7 79.2 OUTPUT: 225.1 222.4 221.5 TRUE: 225.0 225.0 225.0 ERROR: 0.0% 1.1% 1.5%
	평균상대오차: 1.5016%

표 4. 각 신경망 모델의 크기와 학습시간

신경망모델	입력층	은닉층I	은닉층II	출력층	총 연결강도	학습에 걸린시간 (분/5000 epoch)
NN	3	20	10	3	323	95
HNN	6	17	10	3	332	94
CNN	15	12	8	3	323	86
HYBRID						
LO=3	9	12	8	3	251	74
LO=5	15	12	8	3	323	91

참고: LO = 각 입력유니트의 영역분할 변환의 수




그림 1 비교를 위한 여러 신경망구조




그림 2 신경망을 사용한 구조계수 추정




그림 3 10 층 전단건물 모형




그림 4 각각 신경망 모델의 비교




그림 5 분할영역 수에 따른 학습오차