공학석사학위논문

신경망을 이용한 구조물 손상탐지 기법에서의 정규화 효과 도입

Introduction of Regularization Effect to Structural Damage Detection Scheme Using Neural Network

2003 년 2 월

서울대학교 대학원

지구환경시스템공학부

고　영　곤

신경망을 이용한 구조물 손상탐지 기법에서의 정규화 효과 도입

Introduction of Regularization Effect to Structural Damage Detection Scheme Using Neural Network

지도교수 이 해 성

이 논문을 공학석사학위논문으로 제출함

2002 년 10 월

서울대학교 대학원

지구환경시스템공학부

고 영 곤

고영곤의 공학석사학위 논문을 인준함

2002 년 12 월

위 원 장 張 丞 澔

부위원장 이 해 성

위 원 高 錫 武

초록

구조물의 손상탐지기법은 역해석 문제로 정의된다. 역해석 문제에서는 측정치의 부족과 측정오차에 의한 불안정성 문제가 발생하므로 반드시 정규화 기법이 필요하다. 이 논문에서는 신경망을 이용한 구조물의 손상탐지 기법에서 정규화를 도입하는 방법을 제안한다.

시스템 변수에 대해 근사화된 수학적 모델로부터 얻어진 계산변위와 측정변위의 최소 자승오차 함수를 목적함수로 정의한다. 정규화를 이용한 Newton-Raphson방법과 오차역전파 학습법을 이용하여 최적화를 수행하고 결과를 비교한다. 오차역전파 학습법을 이용한 최적화 과정에서 측정 정보별 민감도를 이용해 활성화 함수로 사용되는 sigmoid함수의 경사도를 조정하여 정규화 효과를 확인한다.

Sigmoid함수의 경사도 조정을 통해 도입한 오차역전파 학습법의 정규화 효과를 신경망을 이용한 구조물 손상탐지 기법에 적용한다. 훈련 및 검증과정에서 부재별 민감도를 이용한 sigmoid함수의 기울기 조정을 통하여 정규화 효과를 도입하고, 예제를 통하여 제안한 방법의 타당성을 검토한다.

주요어

신경망, 오차역전파 학습법, 손상탐지, 정규화, 민감도, sigmoid함수, 근사최소자승 오차함수

학번 : 2001-21185

목차

그림목차

표목차

1. 서론

공용연수의 증가에 따라 구조물의 안정성 확보는 중요한 문제로 대두되고 있고, 이에 따른 구조물의 사용성 및 유지관리의 중요성도 점차 증가 하고 있다. 구조물의 손상은 시공 후 피로나 균열등에 의해 발생하는데, 이러한 손상은 구조물의 안정성에 중요한 영향을 미칠 수 있으므로 정확한 손상 진단을 통해 구조물의 적절한 유지관리가 요구된다.

역해석 문제로 정의되는 구조물 손상탐지 기법은 측정치의 부족으로 인해 해가 유일하지 않을 수 있고, 측정오차로 인해 추정된 해의 크기가 심하게 변하는 불안정성을 갖는 문제이다[Yeo00,Par01,박현우02]. 구조물의 손상탐지를 위해 신경망을 이용한 방법이 여러 연구자들에 의해 진행되어 오고 있다[Pan95, 김성곤96, 김병진97, Yun01, Zen01, Man02, Zub02]. 신경망은 훈련이 완료된 후, 검증하고자 하는 결과를 쉽고 빠르게 구할 수 있는 장점이 있다. 검증데이터가 훈련데이터의 범위 내에 있을 때 정확해 해의 추정이 가능한데, 측정오차로 인해 검증 데이터는 훈련데이터의 범위를 벗어날 수 있다. 기존의 신경망을 통한 손상탐지 연구 방법들은 측정오차로 인해 훈련데이터의 범위를 벗어난 경우에 대해 정확한 해의 추정을 하지 못하였다. 이 논문에서는 신경망을 이용해 구조물의 손상을 탐지하고, 측정오차로 인한 불안정성을 해결하기 위해 정규화 효과를 도입한다.

먼저 계산변위와 측정변위의 차이에 대한 최소자승 오차함수의 최적화를 신

경망에서 사용되는 오차역전파 학습법을 이용하여 수행하고, 오차역전파 학습법에서 정규화 효과를 도입하는 방법을 제안한다. 수학적 모델을 시스템 변수에 대해 Taylor근사하여 계산 변위를 구하는데, 시스템 변수에 대한 근사식을 사용하면 implicit nonlinear optimization이 explicit nonlinear optimization문제로 변환되어 최적화의 반복 계산과정에서 수치연산의 효율성을 높일 수 있다.

Sigmoid함수를 활성화 함수로 이용한 최적화 과정에서 민감도를 이용해 sigmoid함수의 경사도를 조정한다. 민감도가 큰 측정정보는 오차의 영향을 적게 받으므로 경사도를 크게 하고, 민감도가 작은 측정정보는 오차의 영향을 많이 받으므로 경사도를 작게 하여 오차의 영향을 줄인다. Sigmoid함수의 경사도 조정을 통한 오차역전파 학습법의 결과를 정규화를 이용한 Newton-Raphson방법과 비교하여 정규화 효과를 확인한다.

Sigmoid함수의 경사도 조정을 통한 오차역전파 학습법의 정규화 효과를 신경망을 이용한 구조물 손상탐지 기법에 적용한다. 입력층과 출력층으로 구성된 단층신경망에서 정적 변위를 신경망의 입력값으로 사용하고, 부재별 손상정도를 출력값으로 정의한다. 훈련데이터로 사용되는 정적변위는 실제 계측하지 않고 수치적인 계산에 의해 구하는데, 시스템 변수에 의해 근사화된 수학적 모델을 이용하여 구한다. 수학적 모델을 알고 있으므로 민감도를 쉽게 구할 수 있는데, 민감도는 근사화된 변위를 시스템 변수에 대해 미분하여 구한다.

부재별 손상정도를 출력값으로 정의하였으므로, 신경망 훈련 및 검증 과정에서 부재별 민감도 정보를 이용해 sigmoid함수의 경사도를 조정한다. 민감도가

큰 부재는 측정오차보다 손상에 의한 영향을 많이 받으므로 경사도를 크게 하고, 민감도가 작은 부재는 손상보다 측정오차의 영향을 많이 받으므로 경사도를 작게 한다. 훈련과정에서 다르게 사용되었던 부재별 sigmoid함수의 경사도를 검증 과정에서 적용시켜서, 측정오차의 영향을 감소시킨다.

예제를 이용해 sigmoid함수의 경사도 조정을 통한 오차역전파 학습법에서의 정규화 효과를 검증하고, 신경망을 이용한 구조물 손상탐지 기법에 도입하여 정규화 효과를 확인한다.

2. 근사 최소자승 오차 함수의 최적화

대상 구조물의 측정점에서 측정된 변위와 계산된 변위에 대한 최소 자승 오차함수를 최소화 함으로써 구조물의 시스템 변수를 추정한다.

$$\Pi_E = \frac{1}{2}\sum_{l=1}^{nlc}\left\|\tilde{\mathbf{u}}_l(\boldsymbol{\alpha}) - \bar{\mathbf{u}}_i\right\|^2 = \frac{1}{2}\left\|\tilde{\mathbf{U}}(\boldsymbol{\alpha}) - \bar{\mathbf{U}}\right\|^2 \qquad (2.1)$$

여기서, $\tilde{\mathbf{U}}$ 와 $\bar{\mathbf{U}}$ 는 각 i번째 하중단계에서 해석모델에 의해 계산된 변위와 측정한 변위를 행방향으로 각각 정렬함으로써 얻어진 벡터들이고, *nlc*는 하중단계의 개수이다. 또한 α 는 시스템 변수이고, $\|\cdot\|$는 벡터의 Euclidean norm이다.

식(2.1)은 측정치의 빈곤함에 의해 해가 유일하지 않을 수 있고, 약간의 측정오차에 의해서도 추정된 해의 크기가 심하게 변하는 해의 불연속성 문제이다 [Yeo00,Par01,박현우02]. 일반적으로 시스템 변수보다 측정치의 개수가 부족한데, 실제적으로 측정치의 개수가 시스템 변수의 개수보다 많더라도 각각의 측정치들이 서로간에 독립적이지 못하기 때문에 해의 개수가 부족한 비유일성 문제가 발생한다. 그리고 측정치에는 오차가 포함되기 마련인데, 작은 오차로 인한 측정치의 변화라도 매우 작은 특이치를 통해 그 값이 크게 증폭되어서 최적화를 위한 반복단계가 진행될수록 그 차이가 점점 커져서 최종적인 추정된 해가 물리적인 의미를 상실되는 불연속성인 문제가 발생하게 된다. 이러한 역해석 문제에서의 불안정성을 해소하기 위해 정규화 기법을 도입한다.

2.1 근사 최소자승 오차 함수

식(2.1)에서 계산된 변위 벡터는 식(2.2)의 수학적 모델을 이용하여 구하는데, 손상은 부재별 기준 강성값의 변화량으로 표현한다.

$$\tilde{\mathbf{u}} = \mathbf{Bu}(\mathbf{X} + \boldsymbol{\alpha}\ \mathbf{X}) = \mathbf{BK}^{-1}(\mathbf{X} + \boldsymbol{\alpha}\ \mathbf{X})\mathbf{P}_i \tag{2.2}$$

여기서 $\mathbf{P}_i$는 각 단계별 작용하중이고, $\tilde{\mathbf{u}}$ 는 각 하중단계별 계산변위이다. $\tilde{\mathbf{u}}$ 를 각 하중단계별로 행방향으로 정렬하면 식(2.1)에서의 계산 변위 $\tilde{\mathbf{U}}$ 를 구할 수 있다. $\mathbf{X}$는 부재별 기준 강성으로서 1.0으로 고정된 값을 가지 있고, $\boldsymbol{\alpha}$는 임의의 부재에서 손상정도를 나타내는 강성감소 계수이다. 기준강성과 기준강성에 대한 강성감소 계수의 변화량을 합한 값이 최종 강성이 된다.

그림 1은 부재 강성감소 계수로서 기준강성이 1.0이므로 -1.0에서 0.0사이의 값을 가진다. 강성 감소계수 값이 -1.0이면 기준강성과 기준강성의 변화량의 값을 합산한 최종적인 강성의 합은 0.0이 되어서 100% 손상이 있는 완전 손상이 되고, 강성 감소계수가 0.0이면 기준강성과 기준강성의 변화에 대한 강성의 합은 1.0이 되어서 손상이 없는 경우이다.

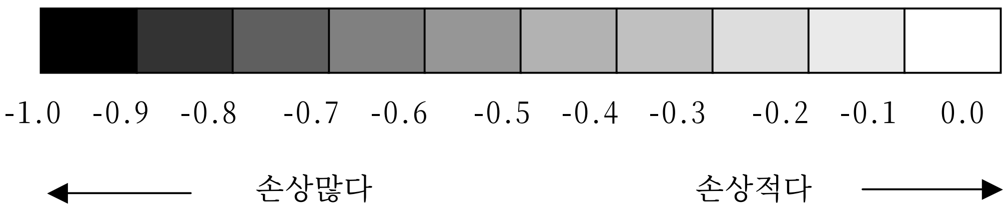

그림 1. 부재 강성 감소 계수 α

수학적 모델을 시스템 변수에 대해 Taylor Expansion하여 근사화된 계산변위를 구한다. 먼저 식(2.2)에서 강성도 행렬을 $\boldsymbol{\alpha}$에 대해 Taylor Expansion하여 근사화된 강성도 행렬을 구한다.

$$\mathbf{K}^{-1}(X_i+\alpha_i X_i)=\mathbf{K}^{-1}(X_i)+\sum_i \frac{\partial \mathbf{K}^{-1}}{\partial x_i}\alpha_i X_i+\frac{1}{2}\sum_j\sum_i \frac{\partial^2 \mathbf{K}^{-1}}{\partial x_j \partial x_i}\alpha_i\alpha_j X_i X_j+ \frac{1}{6}\sum_m\sum_j\sum_i \frac{\partial^3 \mathbf{K}^{-1}}{\partial x_m \partial x_j \partial x_i}\alpha_i\alpha_j\alpha_m X_i X_j X_m+\cdots \tag{2.3}$$

여기서 $\mathbf{U}_u$ 는 기준 강성을 이용한 변위벡터이고, $\hat{\mathbf{K}}_i$ 와 $\hat{\mathbf{K}}_{ij}$ 는 식(2.4), (2.5)에서 보듯이 $\mathbf{K}\mathbf{K}^{-1}=\mathbf{I}$ 를 부재별 기준 강성 $\mathbf{X}$에대해 미분하여 얻을 수 있다.

$$\frac{\partial \mathbf{K}^{-1}}{\partial x_i}=-\mathbf{K}^{-1}\frac{\partial \mathbf{K}}{\partial x_i}\mathbf{K}^{-1}=-\hat{\mathbf{K}}_{,i}\mathbf{K}^{-1}=-\hat{\mathbf{K}}_i\mathbf{K}^{-1} \tag{2.4}$$

$$\frac{\partial^2 \mathbf{K}^{-1}}{\partial x_j \partial x_i}=\hat{\mathbf{K}}_{,j}\hat{\mathbf{K}}_{,i}\mathbf{K}^{-1}+\hat{\mathbf{K}}_{,i}\hat{\mathbf{K}}_{,j}\mathbf{K}^{-1}=\hat{\mathbf{K}}_{ij}\mathbf{K}^{-1} \tag{2.5}$$

식(2.3)의 근사화된 강성행렬을 식(2.2)의 수학적 모델에 대입하여 다음 식 (2.6)과 같이 근사화된 변위를 구한다.

$$\begin{aligned}\mathbf{u}_l(X_i+\alpha_i X_i)&=\mathbf{K}^{-1}(X_i+\alpha_i X_i)\mathbf{P}_l\\ &=\mathbf{K}^{-1}(X_i)\mathbf{P}_l-\alpha_i X_i\hat{\mathbf{K}}_i\mathbf{K}^{-1}\mathbf{P}_l+\frac{1}{2}\alpha_i\alpha_j X_i X_j\hat{\mathbf{K}}_{ij}\mathbf{K}^{-1}\mathbf{P}_l+\cdots\\ &=\mathbf{u}_l^u-\alpha_i X_i\hat{\mathbf{K}}_i\mathbf{u}_l^u+\frac{1}{2}\alpha_i\alpha_j X_i X_j\hat{\mathbf{K}}_{ij}\mathbf{u}_l^u+\cdots\end{aligned} \tag{2.6}$$

근사화된 변위를 이용하여 민감도 및 근사화된 목적함수를 구하는데, 변위를 시스템 변수에 대하여 미분하여 다음과 같이 민감도를 구한다.

$$\frac{\partial \mathbf{u}}{\partial \alpha_p} = -X_p \hat{\mathbf{K}}_p \mathbf{u}_u + \frac{1}{2}\sum_j \alpha_j X_p X_j \hat{\mathbf{K}}_{pj} \mathbf{u}_u + \frac{1}{2}\sum_i \alpha_i X_i X_p \hat{\mathbf{K}}_{ip} \mathbf{u}_u + \cdots \qquad (2.7)$$

그리고 근사화된 변위를 식(2.1)에서의 목적함수에 대입하여 식(2.8), (2.9)와 같이 근사화된 목적함수를 정의한다.

$$\Pi_E \approx \Pi_E^1 = \frac{1}{2}\sum_{l=1}^{nlc} \left\| \mathbf{B}(\mathbf{I} - \alpha_i X_i \hat{\mathbf{K}})\mathbf{u}_l^u - \overline{\mathbf{u}}_l \right\|^2 \qquad (2.8)$$

$$\Pi_E \approx \Pi_E^2 = \frac{1}{2}\sum_{l=1}^{nlc} \left\| \mathbf{B}(\mathbf{I} - \alpha_i X_i \hat{\mathbf{K}} + \frac{1}{2}\alpha_i \alpha_j X_i X_j \hat{\mathbf{K}}_{ij})\mathbf{u}_l^u - \overline{\mathbf{u}}_l \right\|^2 \qquad (2.9)$$

식(2.8)은 시스템 변수의 1차식까지 근사한 변위를 이용한 목적함수이고, 식(2.9)는 시스템 변수의 2차식까지 근사한 변위를 이용한 목적함수로서 시스템 변수에 대한 4차식으로 나타난다.

근사화된 목적함수는 수학적 모델을 Taylor Expansion을 이용하여 근사한 변위를 사용 하였는데, 근사식을 사용함으로써 Explicit Nonlinear Optimization문제는 Implicit Nonlinear Optimization로 바뀌게 되어 수치연산의 효율성이 증가한다. 즉, 기준 강성 **X**를 사용하였기 때문에 최적화 과정의 각 반복단계마다 **X**와 $\hat{\mathbf{K}}_i, \hat{\mathbf{K}}_{ij}$ 등의 값을 새롭게 계산할 필요 없이 처음 계산한 값들을 계속 사용할 수 있으므로 수치연산의 효율성을 증가시킬 수 있다.

목적함수의 최적화 과정은 정규화를 이용한 Newton-Raphson방법과 신경망에서 사용되는 오차역전파 학습법 알고리즘을 이용하여 수행하고 두 가지 방법을 서로 비교 한다.

2.2 **Newton-Raphson을 이용한 최적화**

계산변위와 측정변위의 차이를 이용한 최소자승 오차함수의 최소화 과정을 통해 시스템 변수를 추정하는 역해석 문제에서는 약간의 오차에 대해서도 추정된 해의 크기가 심하게 변할 수 있는 불연속성을 가지고 있다. 또한 측정치의 개수가 시스템 변수의 개수보다 작은 비유일성 문제까지 발생한다. 이러한 불안정성 문제를 해결하기 위해 Newton-Raphson방법에서는 다음과 같은 정규화 함수를 도입한다.

$$\Pi_R = \frac{1}{2}\lambda^2 \|\boldsymbol{\alpha} - \boldsymbol{\alpha}_0\|^2 \tag{2.10}$$

여기서 λ는 정규화 계수이고, α_0는 시스템변수의 기준값이다.

정규화 함수를 도입하여 시스템 변수의 2차식까지 근사한 목적함수는 다음과 같이 수정된다.

$$\begin{aligned} \underset{\alpha}{\text{Min}}\, \Pi &= \Pi_E + \Pi_R \\ &\approx \frac{1}{2}\sum_{l=1}^{nlc}\left\| \mathbf{B}(\mathbf{I} - \alpha_i X_i \hat{\mathbf{K}} + \frac{1}{2}\alpha_i\alpha_j X_i X_j \hat{\mathbf{K}}_{ij})\mathbf{u}_l^u - \bar{\mathbf{u}}_l \right\|^2 + \frac{1}{2}\lambda^2\|\boldsymbol{\alpha}\|^2 \end{aligned} \tag{2.11}$$

수정된 목적함수을 이용하여 Newton-Raphson방법에서 필요한 그래디언트와 헤시안을 구하면 다음과 같다.

$$\mathbf{G} = \mathbf{U}^r\mathbf{S} + \lambda^2\boldsymbol{\alpha} \tag{2.12}$$

$$\mathbf{H} \approx \mathbf{S}^T\mathbf{S} \tag{2.13}$$

여기서 $\mathbf{U}^r$ 은 $\tilde{\mathbf{U}} - \overline{\mathbf{U}}$ 로 정의된 변위잔차이고, $\mathbf{S}$ 는 $\tilde{\mathbf{U}}$ 에 대한 민감도 행렬이다. $\mathbf{G}$ 와 $\mathbf{H}$ 는 목적함수의 그래디언트와 헤시안 행렬이다. 여기서 목적함수의 헤시안 행렬은 변위의 일차 민감도 만으로 근사하는 Gauss-Newton행렬을 사용하였다.

최적화의 반복단계에서 시스템 변수의 증분을 구하여 시스템 변수의 값을 구하는 과정은 다음과 같다.

$$\begin{aligned} \boldsymbol{\alpha}_k &= \boldsymbol{\alpha}_{k-1} + \Delta\boldsymbol{\alpha} \\ &= \boldsymbol{\alpha}_{k-1} - \mathbf{H}^{-1}\mathbf{G} \end{aligned} \tag{2.14}$$

정규화 함수가 포함된 오차함수를 최소화 과정에서 정규화 계수 λ에 대한 결정이 필요한데, 이는 변위에 대한 민감도 행렬을 특이치 분해(Singular Value Decomposition)하여 사용한다. 이 논문에서는 특이치를 이용하여 정규화 계수를 결정하는 방법 중에서 GMS(Geometric Mean Scheme)방법, L-curve방법을 사용한다[박현우02]. GMS방법에서는 시스템 변수에 대한 1차 및 2차 근사한 식을 사용하고, 시스템 변수에 대한 선형함수가 필요한 L-curve방법에서는 1차 근사한

식을 사용한다.

2.3. 오차역전파 학습법을 이용한 최적화

2.3.1. 오차역전파 학습법

오차역전파 학습법은 신경망의 오차최소화 과정에서 쓰이는 방법이다. 신경망은 인간의 뇌를 구현하는 것을 목적으로 하여, 컴퓨터 알고리즘에 의한 인공지능을 개발하고자 하는 노력으로 시작되었다. 인간의 뇌가 어떠한 정보에 대해 반복적인 학습을 통하여 장기기억 형태로 정보를 저장하는 것과 같이 신경망은 입력과 출력과의 관계를 반복 학습을 통하여, 그 연결강도에 정보를 저장한다.

시스템의 출력과 출력의 정해에 대한 차이를 오차로 정의하고, 오차를 최소화 하는 과정에서 사용되는 방법중의 하나가 오차역전파 학습법이다[Sim99]. 즉 오차역전파 학습법은 먼저 입력과 연결강도의 선형 결합값을 구한 후, 이를 활성화 함수에 대입하여 구한 시스템의 출력값과 출력의 정해인 목표값의 차이에 대한 오차의 총합을 구하여 그 합이 최소화 되도록 반복 계산을 하는 방법이다. 오차의 최소화 과정에서 연결강도의 변화는 연결강도 공간상에 주어지는 오차의 제곱을 높이로 하는 곡면에 대해 그 값이 가장 작은 방향으로 기울기가 감소하게 된다. 이러한 오차의 최소화 과정을 통하여 연결강도에 시스템의 정보를 저장한다.

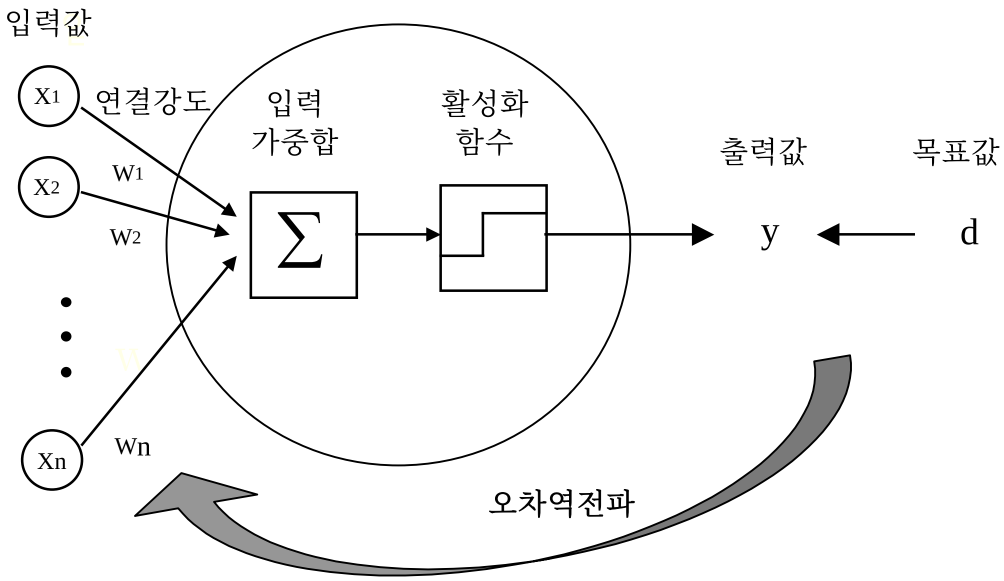

그림 2. 신경망의 구성

그림 2에서는 신경망의 구성 성분과 정의된 오차에 대한 역전파 과정을 나타내었다. 그림에서 보듯이 신경망은 층(layer)으로 배열된다. 기본 처리 요소인 노드는 층으로 배열되는데 하나의 층에 있는 노드는 다음 층의 노드와 연결된다. 연결고리에는 하나의 입력사항이 다음 노드로 넘어갈 때, 그 입력 사항의 중요도를 조정하는 가중치를 매긴다. 가중치를 변화 시킴으로써 시스템은 입력 사항들의 어떤 결합이 가장 중요하며 입력 사항들을 적합하게 반영하는지를 학습한다.

오차역전파 학습법의 구체적인 과정은 다음과 같다. 먼저 입력값과 연결강도의 선형 결합으로 연결 가중합을 구하는데 그 식은 다음과 같다.

$$v = \sum_{k=1}^{n} x_k w_k \tag{2.15}$$

여기서 x는 입력 성분이고, w는 연결 가중치, v는 연결 가중합, n은 입력성분의 개수이다. 입력성분의 개수만큼 연결강도의 개수도 정해진다.

입력과 연결강도의 연결 가중합을 구한 후 이를 활성화 함수에 대입하면 출력값이 결정된다. 그림 3은 활성화 함수의 종류를 나타낸 것으로 계단함수, 부분연속함수, sigmoid함수 등이 있다. 활성화 함수는 단조 증가 함수 이어야 하는데, 문제의 목적과 신경망의 학습 특성에 따라 사용할 종류를 결정한다.

이 연구에서는 식 (2.16)의 sigmoid함수를 활성화 함수로 사용하였는데, sigmoid함수는 역치 함수와 선형함수의 특징을 모두 가지고 있는 함수이고, 또한 미분 가능하여 오차의 역전파 학습이 가능하기 때문이다.

$$f(v) = \frac{1}{1 + \exp(-\lambda v)} \tag{2.16}$$

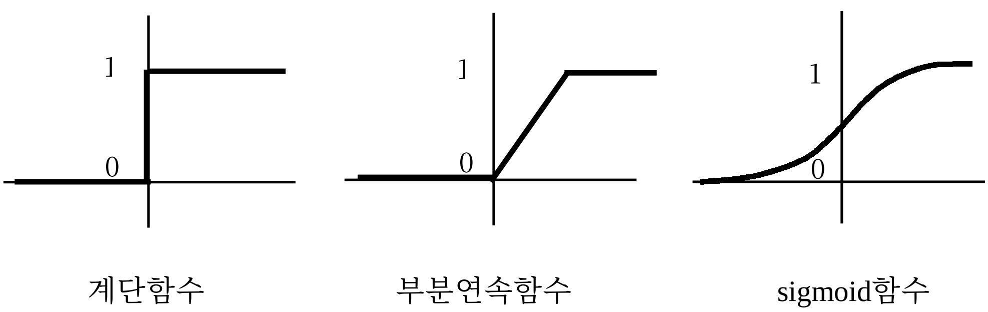

그림 3. 활성화 함수

여기서 λ는 sigmoid 함수의 경사도 인데, 경사도가 크면 입력값의 작은 변화에서도 출력에 대한 패턴의 구분이 커져서 연산시간에 대한 단축될 수 있지만, 훈련과정에서 수렴성 여부를 보장할 수 없고 반대로 경사도가 작으면 입력값의 변화에 대한 출력 패턴의 구분이 작아져서 연산시간이 늘어나는 단점이 있다. 그러므로 주어진 문제에 따라 적절한 λ값을 사용한다.

신경망의 오차역전파 학습과정은 신경망의 출력값과 목표값의 차이에 대한 오차를 최소화 과정인데 다음과 같이 활성화 함수를 통과한 시스템의 출력값과 정해인 목표값의 차이를 오차로 정의한다.

$$E = \sum_{i=1}^{np} (y_i - d_i)^2 \tag{2.17}$$

여기서 y는 신경망의 출력값, d는 목표값 이고, np는 훈련패턴의 개수이다.
정의된 오차를 최소화 하는 방향으로 연결강도 조정하는데 그 과정은 다음과 같이 오차함수에 대한 chain rule을 이용하여 연결강도의 변화량을 구하고, 이 과정을 훈련패턴의 개수만큼 반복계산 한다.

$$w_{i+1} = w_i + \Delta w_i \tag{2.18}$$

$$\begin{aligned} \Delta w_i &= -\eta \nabla E = -\eta \frac{\partial E}{\partial w_i} = -\eta \frac{\partial E}{\partial (v)} \frac{\partial (v)}{\partial w_i} \\ &= -\eta \frac{\partial E}{\partial y} \frac{\partial [f(v)]}{\partial (v)} \frac{\partial (v)}{\partial w_i} \\ &= \eta (1-y) y\, f'(v) x_i \end{aligned} \tag{2.19}$$

여기서 η 는 학습률, f 는 활성화 함수이다. 학습률은 학습의 진행 속도와 관계된다. 학습률이 크면 학습이 빨라지지만 수렴하지 못하고 발산할 우려가 있고, 학습률이 작으면 수렴확률은 높아지지만 학습이 완료될 때까지의 시간이 오래 걸린다는 단점이 있다.

이러한 훈련과정에서의 안정성을 위해 모멘텀 항을 도입하였다. 모멘텀 항은 오차값이 이전에 변화하던 방향으로 조정되도록 함으로써, 반복 계산 과정에서 오차의 최소점을 찾지 못하고 진동하는 현상을 방지하여 학습효과를 증대시키는 역할을 한다. 즉, 모멘텀항은 이전의 연결강도의 변화율로서 모멘텀항을 도입한 연결강도 변화량에 대한 식은 다음과 같다.

$$\Delta w_i = \eta(1-y)y\, f'(v)x_i + \beta\Delta w_{i-1} \tag{2.20}$$

여기서, β 는 모멘텀 상수로서 보통 0에서 1사이의 값을 사용한다. 모멘텀항을 사용할 때는 이전단계의 연결강도 변화량을 저장해야 한다는 단점이 있지만, 학습속도에 큰 영향은 없다.

2.3.2. 오차함수의 최적화

근사식에 의해 정의된 목적함수의 최적화를 오차역전파 학습법을 이용하여 수행한다. 즉, 식(2.8)과 식(2.9)와 같이 시스템 변수의 1차식과 2차식에 대해 근사화된 변위를 이용하여 정의된 목적함수를 오차역전파 학습법을 이용한 최적화를 통해 시스템 변수를 추정한다.

먼저 근사항의 차수를 결정해야 하는데, 시스템 변수의 2차항까지 고려한 계산 변위는 다음과 같다.

$$\tilde{\mathbf{u}} \approx \mathbf{B}(\mathbf{I} - \alpha_i X_i \hat{\mathbf{K}} + \frac{1}{2}\alpha_i \alpha_j X_i X_j \hat{\mathbf{K}}_{ij})\mathbf{u}_l^u \tag{2.21}$$

여기서 $\tilde{\mathbf{u}}$ 는 근사화된 계산 변위이다. 식(2.21)의 우변에서 $\mathbf{u}_l^u$ 와 X는 기준변위와 기준강성으로서 주어진 값이고, $\hat{\mathbf{K}}_i, \hat{\mathbf{K}}_{ij}$ 는 기준강성 값을 이용하여 식 (2.4), (2.5)를 통해 구한 값이다. 즉, 식(2.21)에서 손상정도 α를 제외하곤 모두 기지값이다. 그림 4는 오차역전파 학습법을 이용한 최적화 과정을 나타낸 것이다.

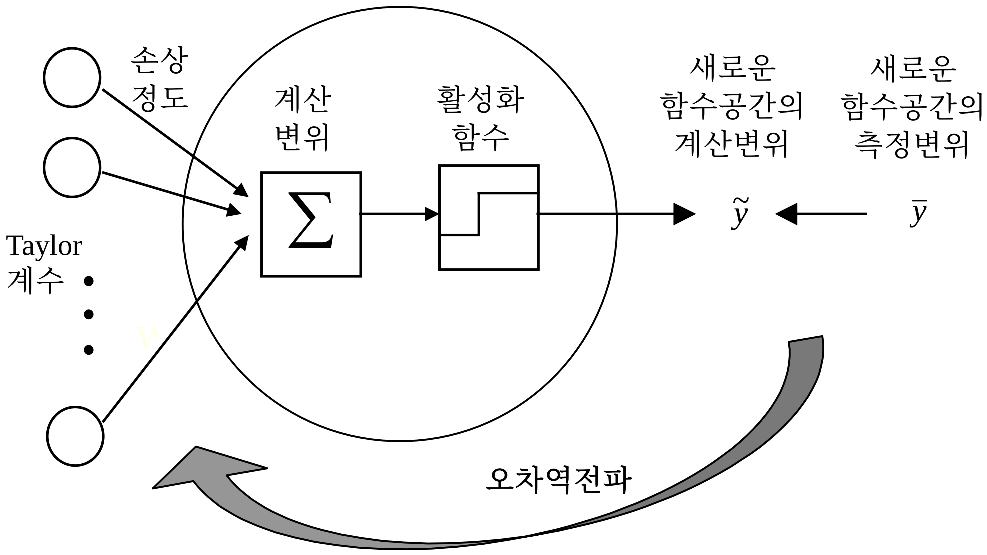

그림 4. 오차역전파 학습법을 이용한 최적화

선형화된 수학적 모델에서 기지값인 Taylor계수를 신경망의 입력값으로 사용하고, 미지수인 손상정도를 연결강도로 사용한다. 식(2.21)에서 보듯이 입력값인 Taylor계수와 연결강도인 시스템 변수와 연결가중합은 계산 변위가 된다. 이 계산 변위를 활성화 함수를 통과 시키면 새로운 함수 공간으로 사상된 계산변위가 되고, 이를 활성화 함수를 통해 새로운 함수 공간으로 사상된 측정변위와 비교하여 그 차이를 최소자승 오차함수로 정의한다. 정의된 오차함수를 오차역전파 학습법을 통해 최적화를 수행한다.

훈련패턴의 개수는 측정변위의 개수와 같다. 최적화 과정에서 한번의 반복계산은 모든 훈련패턴에 대한 오차 최소화 과정을 수행하므로, 최적화 과정에서 한번의 반복계산은 모든 측정변위 개수만큼 시스템 변수의 변화를 수행한다. 그리고 식(2.21)을 보면 한 개의 훈련 패턴 즉, 하나의 변위는 모든 부재 성분들의 결합에 의해 구성되어지고 있음을 알 수 있다.

이 논문에서는 sigmoid함수를 활성화 함수로 사용하였다. S자 형태를 가지고 있는 Sigmoid함수는 활성화 함수 중에서 가장 널리 사용되는 함수로서, 특히 오차역전파 학습법에서는 이 함수를 사용한다. 디지털 형태의 출력값이 나오는 계단함수와는 달리 sigmoid함수는 아날로그 형태의 출력이 나오는 장점이 있고, 연속한 미분이 가능한 장점이 있으므로 오차역전파 학습법에서 사용되는 함수이다. Sigmoid함수는 0.0과 1.0에서 근사적으로 위치하는 두 개의 수평선을 가진다. 입력값이 얼마나 높은지 또는 낮은지와 무관하게 sigmoid함수의 출력은 항상 0.0과 1.0 사이에서 연속적인 값을 가지게 된다.

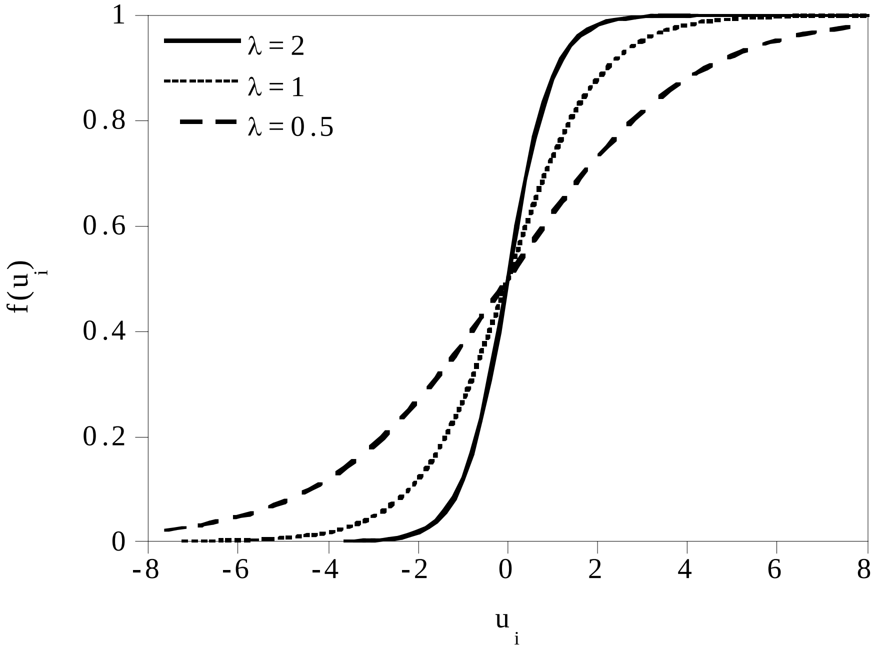

그림 5. 경사도에 따른 sigmoid함수

그림 5는 경사도에 따른 sigmoid함수의 형태를 나타낸 것이다. 그림에서 보듯이 경사도가 높으면 입력값의 변화에 따른 출력값의 변화량이 많아지게 되고, 경사도가 낮으면 입력값의 변화에 따른 출력값의 변화량이 작아지게 된다.

역해석 문제에서는 측정치의 빈곤함과 측정오차로 인한 불안정성 문제가 발생한다. 오차 역전파 학습법을 통해 주어진 근사 최소자승 오차함수의 최적화 문제에서도 이러한 불안정성 문제를 해결해야 하는데, 출력값인 측정 변위별로 sigmoid함수의 경사도를 조정하여 정규화 효과를 도입한다. 식(2.7)에서 구한 근사화된 민감도를 이용하여 신경망의 출력값인 각 변위별로 다른 sigmoid함수의 경사도를 사용한다. 시스템 변수에 대해 1차 근사된 변위를 이용하여 민감도를

구하는데, 민감도는 시스템 변수의 값과 무관한 고정된 값을 가지게 된다. 이렇게 구한 민감도를 다음식과 같은 과정을 통해 적용한다.

$$\kappa_i = \sqrt{\sum_{j=1}^{n} S_{ij}^2} \tag{2.22}$$

여기서 i는 측정변위로서 1부터 m까지의 값을 갖는다. m과n은 각각 측정변위와 부재의 개수를 나타낸다. S는 민감도 행렬이고, κ는 민감도를 각 측정정보별로 norm을 취한 벡터이다. κ에는 각 측정정보별로 민감도 정보가 저장되어 있다. 이를 가장 큰 성분으로 나누어 기준화(normalize)시키면 다음과 같다.

$$\lambda_i = \frac{\kappa_i}{\max \kappa_i} \tag{2.23}$$

이러한 과정을 통하여 가장 큰 민감도를 가진 측정정보의 경사도가 1이고, 다른 측정정보는 가장 큰 민감도를 가진 측정정보의 선형비율로 0과 1사이의 다른 경사도를 가진게 된다.

민감도가 큰 측정정보는 작은 측정정보 보다 상대적으로 측정오차에 대해 둔감하게 반응하므로 sigmoid함수의 경사도를 높여 주어서 출력값의 변화량을 높여주고, 반대로 민감도가 작은 측정정보는 측정오차에 대해 민감하게 반응하므로 sigmoid함수의 경사도를 낮추어서 출력값의 변화량을 낮추게 되어서 오차의 영향을 감소시키게 된다. 따라서 민감도에 따른 측정정보의 sigmoid함수 경사도를 조정하면 정규화 효과를 도입할 수 있다.

2.4. 예제

정규화를 이용한 Newton-Raphson방법과 오차역전파 학습법을 통해 근사 최소자승 오차함수의 최적화를 수행하고 시스템 변수인 손상을 추정하기 위해 그림 6과 같은 구조물을 예제로 한다. 구조물은 12개의 절점과 25개의 부재로 구성된 트러스 구조물이다. 탄성계수는 1000 N/m^2이고, 단면적은 상현재의 경우 112.5 cm^2 , 하현재 93.6 cm^2, 수직재 62.5 cm^2,사재 75.0 cm^2 이다. 손상의 기준값은 0.0 즉, 손상이 없는 상태의 값을 기준으로 하였고, 실제 손상은 그림 7에 나타나듯이 3번 부재가 50%, 9번 부재가 70%의 손상이 있는 상태이다. 측정점은 하현부 6곳의 절점에서 7개의 측정정보를 얻을 수 있다.

각 하중 단계별 재하 조건은 그림 8에 나타나 있고, 하중의 크기는 N이다. 각 단계별로 서로 독립적인 조건이기 때문에 각 하중 단계별로 측정정보가 7개씩, 총 21개의 정보를 얻는다. 하지만, 측정변위 정보가 부재 개수 보다 적기 때문에 이 예제는 비유일성 문제이다. 오차에 의해 추정되는 해의 크기가 변하는 불연속 문제를 포함하기 위해서 측정치에 5%의 오차를 주었다.

식 (2.24)과 같이 반복계산중에 계산변위와 측정치의 상대오차를 비교하여, 그 값이 정해진 값보다 작아지면 수렴하였다고 가정하고, 반복계산을 마친다.

$$\frac{\left\|\tilde{\mathbf{U}}-\bar{\mathbf{U}}\right\|}{\left\|\mathbf{U}\right\|} \le \varepsilon \qquad (2.24)$$

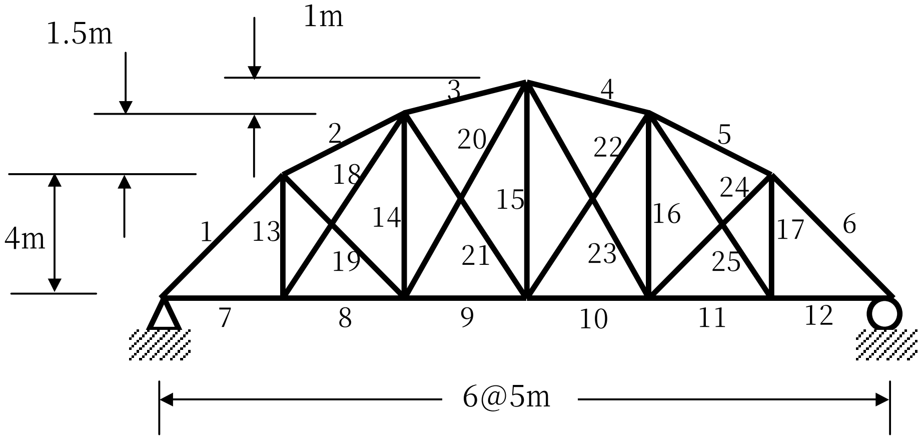

그림 6. 트러스 예제 모델

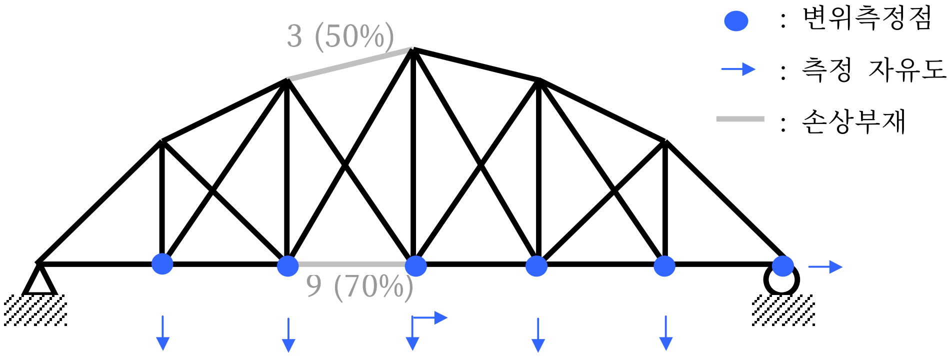

그림 7. 손상부재 및 변위측정점

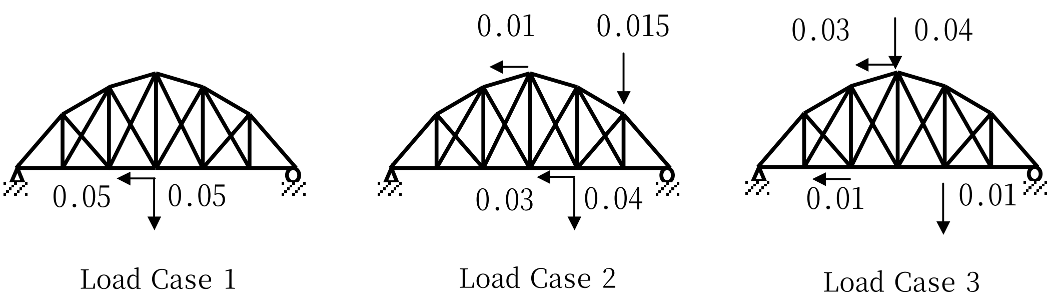

그림 8. 2장 예제의 단계별 작용하중

여기서 ε 은 수렴여부의 판단을 위한 정한 상수로써, 이 논문에서는 $\varepsilon = 10^{-4}$ 을 사용하였다.

먼저 정규화를 이용한 Newton-Raphson방법을 이용하여 식(2.11)의 목적함수를 최적화한다. 이 방법에서는 정규화 함수를 이용하는데, 정규화 계수를 결정하는 방법으로 GMS방법과 L-curve방법을 사용하였다. GMS방법은 시스템 변수의 1차 및 2차 근사한 식에 대해 사용하였고, L-curve방법은 1차 근사한 식에 대해 사용하였다. 측정오차가 없는 경우 시스템 변수의 1차 및 2차 근사에 따른 부재별 손상은 다음 그림 9와 같다.

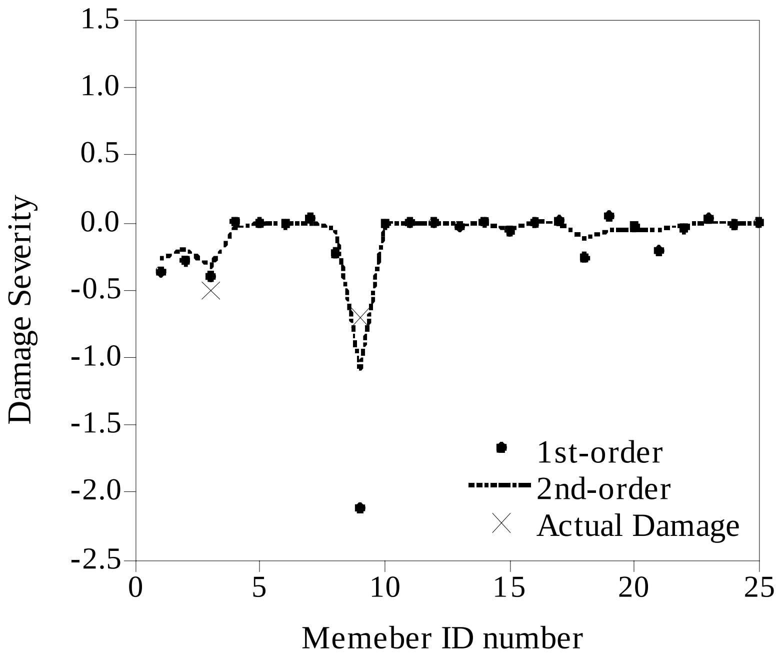

그림 9. 측정오차 없는 경우 Newton-Raphson방법

위 그림 9의 예제는 측정오차가 포함되지 않았지만, 측정치의 개수가 시스템 변수의 개수보다 적은 문제이다. 시스템변수의 근사차수에 의한 해의 영향을 검토하기 위해, 변위에 대한 Taylor 근사에서 시스템 변수의 1차항 까지 근사한 경우와, 2차항 까지 사용한 경우를 비교하였다. 그림을 보면 실제 손상이 발생한 3번 부재의 경우에는 다른 부재에 비해 손상 정도가 지배적이지 않지만, 9번 부재의 경우에는 손상여부를 쉽게 알 수 있다. 1차항과 2차항의 값을 비교하면, 2차항까지 사용한 경우에는 1차항 보다 손상 정도가 많이 개선되었고, 손상 위치 및 손상 정도에 대한 판단이 더 쉬워짐을 알 수 있다. 특히 2차항까지 사용한 경우에는 정해와 차이가 거의 없음을 알 수 있다. 만약 연산과정에서 1차항까지 사용한 경우에 부재 개수(25개) 정도 연산 시간이 소요된다고 가정하면, 2차항 까지는 25+25×25의 개수 정도의 연산 시간이 요구 되고, 만약 3차항 이상이라면 그 수는 기하급수적으로 늘어나게 된다. 따라서 이 예제에서는 해의 정확성 및 연산시간을 고려하여 2차항까지 고려하는 것이 효율적임을 알 수 있다.

그림 10은 측정변위에 오차가 5% 첨가되어 있을 경우, Newton-Raphson방법을 이용하여 시스템 변수의 1차 및 2차 근사에 따른 목적함수의 최적화를 수행한 결과이다. 이 예제는 측정오차로 인해 불연속성 문제와 측정정보가 부재수보다 적은 비유일성 문제가 함께 존재하는 문제이다. 이 문제 역시 GMS방법에서는 시스템의 1차 및 2차 근사식을 이용하였고, L-curve방법에서는 시스템 변수의 1차식을 사용한 경우에 대하여 정규화 계수를 결정하였다.

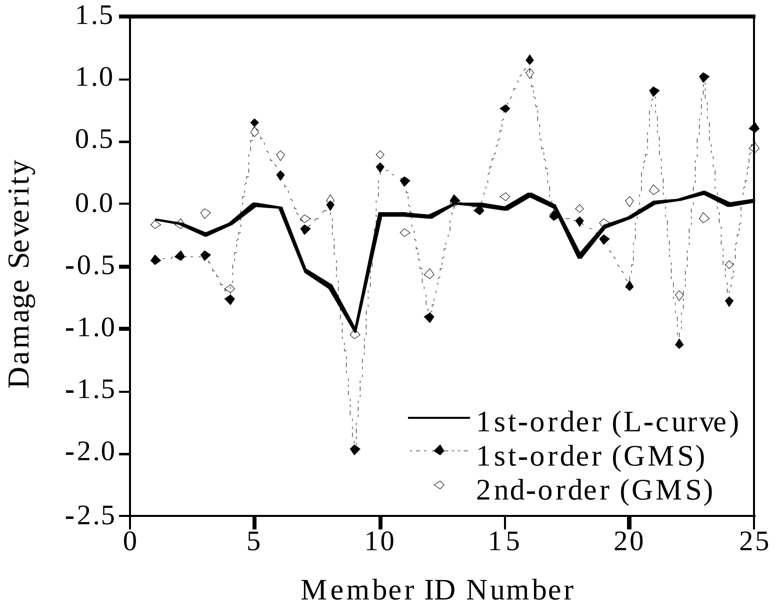

그림 10. 측정오차 5% 경우 Newton-Raphson방법

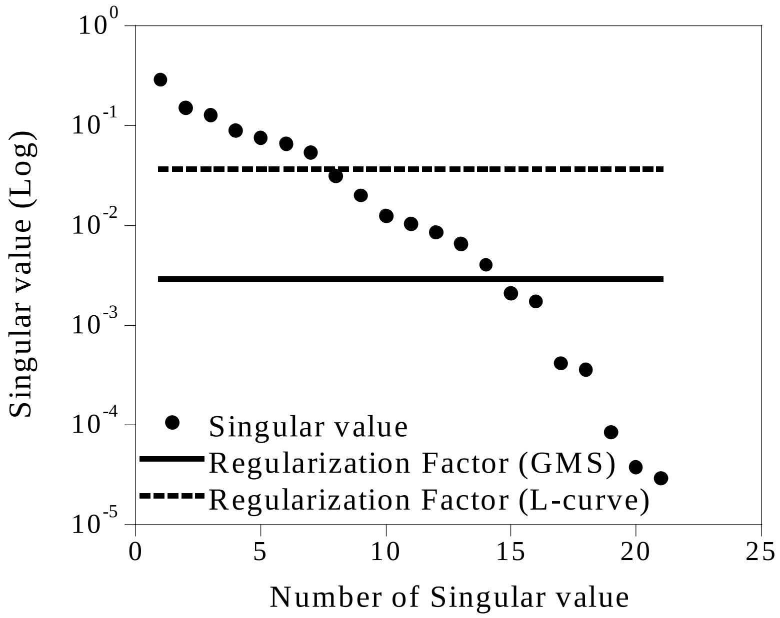

그림 11. 1차 근사, 측정오차 5% 경우 정규화 계수

먼저 1차 근사한 식에 대해 GMS방법과 L-curve방법에 대해 비교하였다. 비록 측정오차로 인해 정확한 해의 추정을 하진 못하였지만 L-curve방법은 해의 진동 폭을 줄이고, 지배적인 손상이 발생한 9번 부재의 손상 위치를 잘 추적하고 있음을 알 수 있다. 이에 비해 GMS방법은 추정된 해의 진동 폭이 너무 커서 손상의 위치에 대한 정보를 찾기 불가능한 물리적인 의미를 잃어버린 결과가 출력되고 있음을 알 수 있다. 시스템 변수의 2차 근사에 대한 식에 대해서도 GMS방법은 1차 근사에 대한 경우에 비해 진동 폭이 줄어들긴 했지만, 마찬가지로 손상에 대한 정보를 찾기가 불가능 하다. 이는 GMS방법이 적절한 정규화 계수의 결정하지 못하였기 때문이다.

GMS방법이 적절한 정규화 계수를 결정하지 못한 이유는 민감도의 특이치 분포를 보면 알 수 있다. 1차 근사한 식을 사용하고, 측정오차가 5%일 경우 두 방법에 따른 정규화 계수 및 민감도의 특이치를 보면 다음 그림 11과 같다. 이 예제는 21개의 측정 정보를 가지고 있으므로, 21개의 특이치를 가지고 있다. 그림 11의 특이치 분포를 보면 일정하게 변하던 특이치 분포가 16번째와 17번째 사이에서 갑자기 떨어지고 있음을 알 수 있다. 특이치의 최대값과 최소값을 가지고 정규화 계수를 결정하는 GMS방법에서는 최소값을 21번째 특이치로 사용하는데, 그림에서 보듯이 16번째 특이치가 최소값으로 결정되어야 적절한 정규화 계수가 결정될 수 있다. 이는 시스템 변수에 대한 근사식을 사용하였기 때문에 GMS방법이 적절한 정규화 계수를 결정하지 못한 것이다. 반면에 L-curve 방법은 적절한 정규화 계수를 결정하고 있음을 그림을 통해 확인할 수 있다.

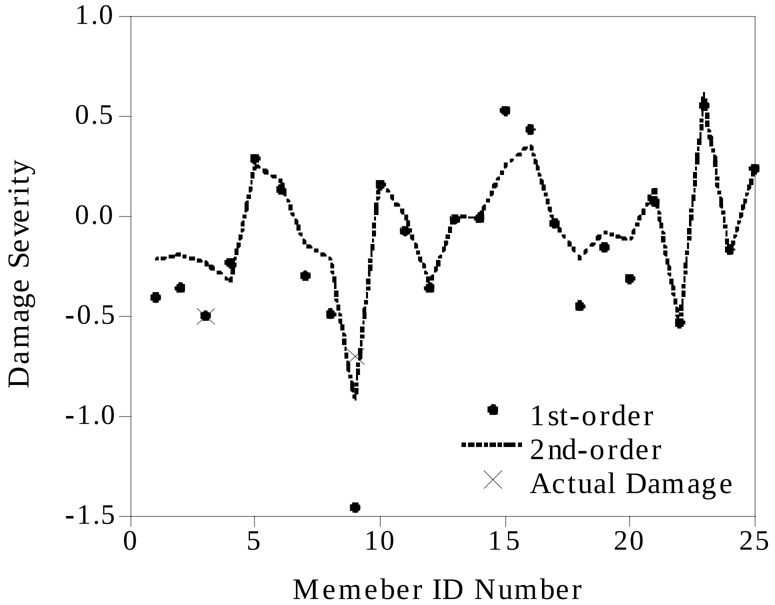

그림 12. 측정오차 5% 경우 일정한 경사도를 사용한 오차역전파 학습법

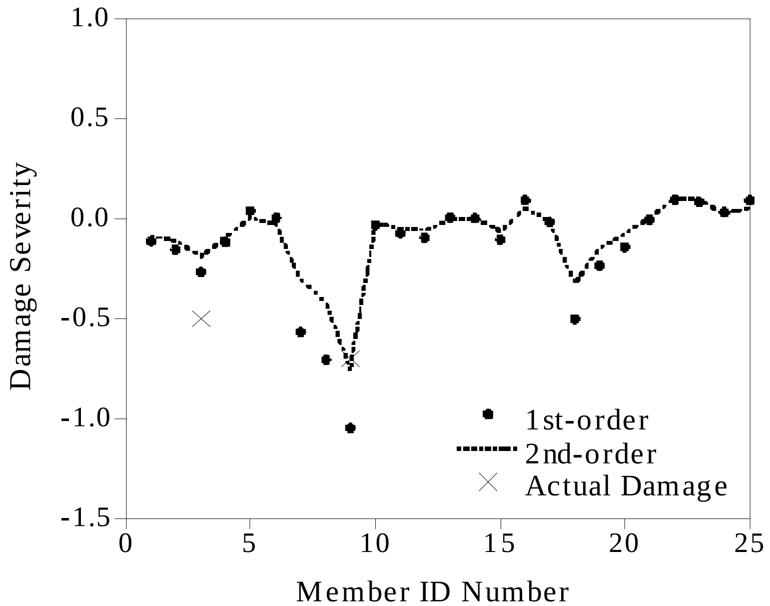

그림 13. 측정오차 5% 경우 다른 경사도를 사용한 오차역전파 학습법

다음은 오차역전파 학습법을 이용한 식(2.11)의 목적함수를 최적화한 결과이다. 그림 12는 측정오차가 5%인 경우, sigmoid함수의 경사도를 일정하게 사용한 경우에는 시스템 변수의 근사항의 차수에 관계없이 해의 진동 현상이 발생함을 알 수 있다. 측정오차로 인해 발생한 불안정성 문제를 해결하지 못하였기 때문이다.

그림 13은 민감도를 이용해 측정변위 정보별로 sigmoid함수의 경사도를 다르게 한 경우인데, 일정한 경사도를 사용한 경우에 비해 해의 진동 폭이 줄어들고 손상의 위치 및 정도를 파악하는데 적절한 결과를 나타내었다. 이는 오차에 대해서 반응정도가 큰 민감도가 작은 측정변위 정보에 대해 sigmoid함수의 경사도를 낮추고, 오차에 대해 상대적으로 반응정도가 작은 민감도가 큰 측정변위의 경사도를 높여주어 오차에 대한 영향을 최소화 하였기 때문이다. 그림 12와 그림 13을 비교하면 민감도를 이용해 측정변위 정보별로 sigmoid함수의 경사도를 다르게 하는 방법이 정규화 효과를 나타내고 있다는 것을 알 수 있다. 비록 3번 부재의 경우 손상의 추적이 잘 되지 않았지만, 이는 측정정보가 시스템 변수의 개수보다 작기 때문에 발생하는 현상으로서 지배적인 손상 부재인 9번 부재는 만족할 만한 손상 정보를 주고 있다. 그림 13을 보면 시스템 변수의 2차까지의 근사식을 이용한 경우가 1차식까지의 근사식을 사용한 경우보다 정확한 해의 추정을 하고 있는 것을 알 수 있다.

그림 14와 15는 정규화를 이용한 Newton-Raphson방법과 민감도를 이용해 sigmoid함수의 경사도를 달리한 오차역전파 학습법의 결과를 비교한 것이다.

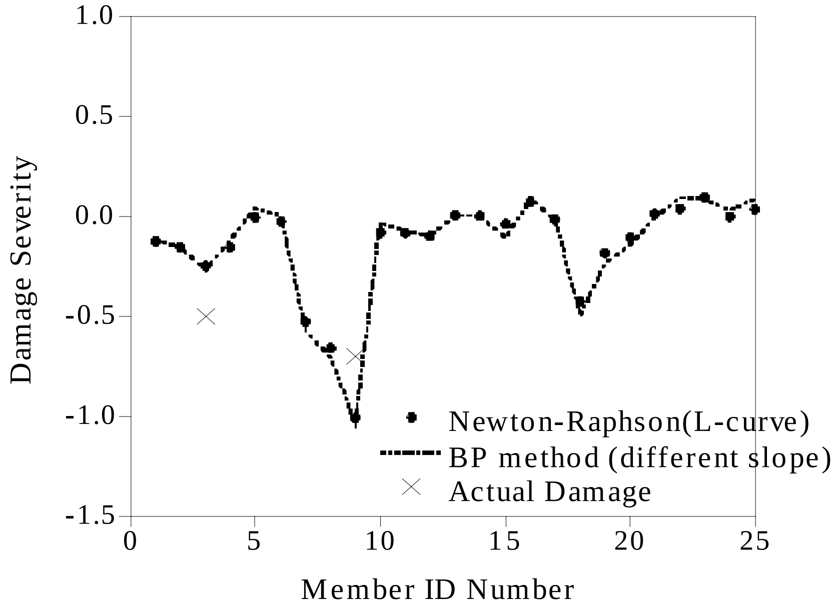

그림 14. 1차 근사식을 이용하고 측정오차 5% 경우의 비교

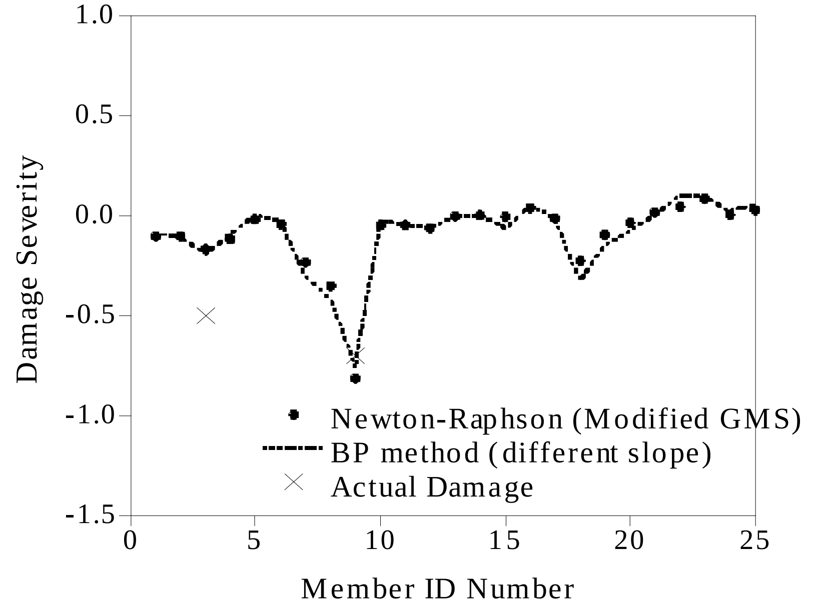

그림 15. 2차 근사식을 이용하고 측정오차 5% 경우의 비교

먼저 그림 14는 측정오차가 5%이고, 시스템 변수에 대한 1차 근사식을 사용한 경우에 Newton-Raphson방법과 오차역전파 학습법을 이용한 최적화 결과를 비교한 것이다. Newton-Raphson방법에서 L-curve방법을 이용하여 정규화 계수를 결정하였다. 오차역전파 학습법은 민감도를 이용하여 측정정보별로 sigmoid함수의 경사도를 조정하였다. 두 가지 방법이 거의 비슷한 결과를 출력하고 있음을 알 수 있다.

그림 15는 측정오차가 5%이고, 시스템 변수에 대한 2차 근사식까지 사용한 경우인데, 오차 역전파 학습법은 마찬가지로 sigmoid함수의 경사도를 조정한 방법이다. Newton-Raphson방법에서는 수정된 GMS방법 사용하였다. 여기서 수정된 GMS방법은 적절한 정규화 계수의 추정을 위해 그림 2.11에서 보듯이 21번째 특이치를 최소값으로 결정한 것이 아니라, 특이치 분포가 급격하게 변하는 16번째 특이치를 최소값으로 결정한 것이다. 이러한 과정을 통한 결과를 비교하면 1차식과 마찬가지로 두 가지 방법이 비슷하다.

그림 14와 15의 결과가 비록 만족할 만한 손상 추정 결과는 아니지만, 민감도 정보를 이용해 측정정보별로 sigmoid함수의 경사도를 다르게 조정함으로써 오차 역전파 학습법에서 정규화 효과를 도입할 수 있음을 알 수 있다.

3. 신경망의 정규화 효과

신경망을 이용한 손상탐지 기법에서는 주어진 손상 정보에 대한 훈련 과정을 통해 신경망의 연결강도에 손상으로 인한 구조거동에 관한 인과 관계를 저장한다[김병진97]. 훈련이 완료되면 연결강도에 저장된 정보를 이용하여 구하고자 하는 입력값에 대한 출력을 빠르게 구할 수 있다. 하지만 구하고자 하는 입력값에 측정오차가 포함되어 있을 때 오차로 인해 출력값인 손상 정보의 신뢰성이 떨어지게 되므로, 측정 오차 대한 영향을 줄이는 과정이 필요하게 된다.

오차 역전파 학습법을 이용한 목적함수의 최적화 과정에서 민감도를 이용한 sigmoid함수의 경사도를 조정을 통해 정규화 효과를 도입할 수 있었다. 신경망의 훈련 및 검증 과정에서 이와 같은 방법을 통해 정규화 효과를 제어할 수 있다. 이 장에서는 신경망을 이용한 손상탐지 기법과 민감도를 이용해 측정오차에 대한 영향을 감소시키는 과정을 살펴본다.

3.1. 신경망의 정의

신경망 이론은 인간의 뇌를 모방하여 인공적인 지능을 개발하고자 하는 이론으로서 뇌의 신경 세포간의 연결관계와 기억의 인지 학습과정을 토대로 인공세포들의 망을 구성하여 뇌의 활동과 유사한 기능을 구현하고자 한다. 인간의 기억에 대한 학습 과정은 단기 기억을 학습을 통하여 장기 기억의 형태로 저장

하게 되는데, 이러한 인지학습 과정을 통한 기억의 저장 형태를 모방하여 인공적인 신경망을 구성한다. 뇌는 엄청난 수의 신경 세포들의 복잡한 연결로 이루어져 있지만 신경망 이론은 이러한 뇌의 신경 세포를 단순화 시켜 수학적으로 모델링한 것이다. 신경망은 그림 2에서 보듯이 정보가 들어오는 입력층과 입력이 들어가는 뉴런에 미치는 영향의 크기를 조절하는 연결강도, 입력과 연결강도의 연결가중합을 통해 새로운 함수 공간으로 사상시키는 활성화 함수와 활성화 함수로부터 나온 출력층으로 구성되어 있다.

표 1은 인간의 뇌의 신경세포에 의한 학습과정과 신경망을 이용한 학습과정을 비교한 것이다.

	뇌의 신경세포	인공신경망
입력	연결된 모든 신경 세포 들로부터 정보들이 전달	연결된 모든 인공 신경세포 들로부터 정보들이 전달
연결강도	전달된 정보들은 시냅스의 상태에 따라 그 값들이 조절	전달된 정보들에 연결강도 가 곱해져 그 값들이 조정
연결가중합	조절된 값들은 모두 합산	조정된 값들은 모두 합산
출력	합산된 값이 역치 이상이 되면 신경세포는 발화	합산된 값에 활성 함수가 취해져 그 값이 출력

표 1. 뇌와 신경망의 학습과정 비교

신경망은 입력과 목표 출력값을 알고 있는 훈련데이터를 이용하여 훈련과정을 통해 연결강도에 시스템의 정보를 저장한다. 입력과 출력값이 충분한 인과 관계가 있는 훈련자료를 선택하여 학습을 시키고 나면, 훈련 과정에서 사용되지 않았지만 출력의 정해를 알고 있는 데이터를 이용하여 설계된 신경망의 타당성 여부를 검토한다. 연결강도는 시스템의 입력과 출력간의 인과 관계에 의한 정보를 저장하고 있지만, 수학적인 의미를 부여하기 힘든 블랙박스이다.

신경망은 단순한 기능을 가진 무수히 많은 신경세포 또는 처리소자들이 병렬 연결된 연산구조로 되어 있다. 그 특징은 다음과 같다.

(1) 각 신경세포는 다른 신경세포들과 완전히 독립된 기능을 갖는다. 즉, 각 신경세포의 출력은 자신과 연결된 연결강도를 통하여 직접 전달되는 정보에만 의존할 뿐, 다른 정보들과는 무관하다. 이와 같은 특징으로 인하여 병렬처리가 가능하므로 연산속도가 매우 빠르다.

(2) 신경망은 무수히 많은 연결강도를 가지고 있다. 따라서 정보의 분산표현 및 처리가 가능하다. 또한 중복성이 크므로 fault-tolerant 할뿐만 아니라 일부의 정보로부터 전체를 얻을 수 있는 특성을 갖는다.

(3) 학습이나 훈련을 통해 연결강도를 조정함으로써 새로운 정보를 추가하거나 변경할 수 있는 적응특성을 가지고 있다

신경망 모델을 1943년에 McCulloch와 Pitts가 발표한 이후, 1949년 Hebb은 학습이나 훈련이 진행됨에 따라 신경세포들 사이의 연결강도가 변화한다는 생물학적인 학습의 원리를 발견하였고, 1958년 Rosenblatt가 학습기능을 갖춘 최초의

신경망인 퍼셉트론을 발표 하였다. 이후 Adaline (Adaptive linear neuron), 다층 퍼셉트론 (multi-layer perceptron)과 ART (Adaptive Resonance Theory), SOM (Self-Organizing Map)등 다양한 신경망 모델이 등장하였다. 이 논문에서는 오차역전파 학습법을 신경망의 학습 과정에 적용하였다.

3.2. 신경망을 이용한 손상탐지

이 논문에서는 신경망 이론을 이용하여 토목구조물의 손상을 추정하고자 한다. 구조 시스템에 신경망을 적용시키기 위한 첫 단계는 신경망이 입력 정보를 이용해서 개별 구조물의 손상정보를 인지할 수 있도록 훈련자료를 선택하는 것이다. 신경망에서는 측정된 데이터의 반복훈련 과정을 통해 연결강도에 손상과 손상으로 인한 구조거동의 변화에 관한 인과관계를 저장한다. 구조물에서 측정된 데이터는 구조물의 정적 혹은 동적 정보를 포함하고 있으며, 손상은 이러한 정보에 영향을 미치게 된다. 따라서 손상된 구조물에서 측정된 데이터는 손상되지 않은 구조물의 측정 데이터와 비교할 때 손상의 위치 및 정도에 관한 정보를 가지고 있다.

구조물의 정적 혹은 동적 특성의 변화를 이용하여 구조물의 손상을 평가하는 연구가 많이 진행되어 오고 있다. 신경망을 이용한 구조물의 손상기법은 훈련이 완료된 후 미지의 입력에 대한 손상정보를 쉽고 빠르게 구할 수 있는 장점이 있다. 모든 부재의 손상을 탐지하기 위해서는 방대한 훈련자료가 필요한데, 이를 극복하기 위해 대상부재를 한정하는 방법에 관한 연구도 진행되고 있다.

윤정방과 방은영은 동적 데이터를 이용하여 구조물의 손상을 평가하였다[Yun00,Yun01]. Substructure를 이용해 대상 부재를 한정하였고, 모드 성분의 절점간 상대치의 민감도 분석을 수행하여 측정점을 선택하였다. Noise-Injection방법을 통하여 측정오차가 포함된 경우에도 효율적으로 손상을 평가하였다.

김성곤은 가속도계와 변위계에서의 시그널을 이용한 구조물의 손상위치 및 정도를 인공 신경망으로 밝히는데 있어서 모의 실험을 이용하였다. 훈련자료로는 0.5부터 1사이로 일반화된 시간영역에서의 가속도를 이용하였다[김성곤96].

Zubaidy,A.와 Haddara,M.R.과 Swamidas.A.S.J는 선박구조물의 side shell을 stiffened plate로 모델링하여, 고유진동수 및 고유벡터를 이용한 side shell의 손상위치 및 정도를 평가하였다[Zub02]. 손상은 균열이 발생한 부재의 경우, 강성도 매트릭스가 0이 된다고 보고 수행하였다.

Pandey와 Barai는 정적변위을 신경망의 입력값으로 사용하고 감소된 구조물의 단면적을 이용하여 2차원 트러스 교량의 손상을 추정하였고, 시간영역에서 동적데이터를 이용하여 손상 탐지를 하는 방법도 연구하였다[Pan95].

이 논문에서는 정적 변위를 신경망의 입력값으로 사용하고, 출력값을 부재별 손상정도로 정의한 단층 신경망을 이용해 구조물의 손상 탐지를 수행하였다. 연결강도에는 정적변위의 변화 따른 손상에 관한 정보를 저장하게 된다. 즉, 각 부재별 손상 케이스에 따른 정적 변위를 훈련패턴으로 정의하여, 훈련과정을 통해 측정변위에 따른 손상의 정보가 연결강도에 입력되게 된다.

신경망에서 훈련패턴을 정의할 때 가장 중요한 요소는 훈련 패턴의 선정이다.

훈련패턴의 입력과 출력값이 충분한 인과 관계가 있어야 하고, 훈련패턴이 정의된 출력값에 대한 충분한 정보를 줄 수 있도록 그 개수가 부족하지 않아야 한다. 손상이 발생한 구조물에서의 정적변위는 손상이 발생하지 않은 구조물의 변위와 비교할 때, 손상의 위치 및 정도에 관한 정보를 충분히 가지고 있으므로 입력과 출력의 충분한 인과 관계가 있다.

구조물의 측정 변위는 구조물의 직접 계측할 수도 있고, 수치적인 연산에 의해 구할 수도 있다. 이 논문에서 다양한 손상에 관한 훈련패턴을 정의하기 위해 수치적인 연산에 의한 측정 변위를 구하였다. 역해석 문제로 정의되는 구조물 손상탐지 기법에서는 측정치의 부족과 측정오차로 인해 불안정성 문제가 발생하게 된다. 신경망의 훈련 및 검증과정에서 입력값으로 사용되는 측정변위는 정의된 수학적 모델에 의해 구하여진 값이므로 이러한 불안정성 문제가 발생한다. 따라서 발생된 불안정성 문제의 해결을 위해 정규화 기법의 도입이 필요하다. 이 논문에서는 신경망의 훈련과정에서 정의된 오차의 최소화를 위해 오차역전파 학습법을 도입하였는데, 훈련 및 검증과정에서 부재별 민감도 정보를 이용해 활성화 함수로 쓰이는 sigmoid함수의 경사도 조정을 통해 정규화 효과를 도입한다.

3.3. 민감도를 이용한 정규화 효과 도입

이 논문에서는 정적 변위를 신경망의 입력값으로 사용하고, 부재별 손상정도를 출력값으로 정의하였다. 활성화 함수는 식(2.16)의 sigmoid함수를 사용하였다.

입력값과 연결강도의 선형결합값인 연결가중합은 정의된 sigmoid함수를 통하여 새로운 함수 공간으로 사상된다. 즉, sigmoid함수를 통과한 연결가중합은 최대값이 1이고, 최소값이 0인 사이에서 비선형 값을 가지는 새로운 함수공간으로 정의된다. 이러한 과정을 통해 구하고자 하는 미지값이 입력될 때, 그 출력값은 0과 1사이의 값을 가지는 smoothing효과가 나타나게 된다. 비록 출력값이 0과 1 사이의 값으로 출력이 되지만, 측정오차로 인한 출력된 손상의 위치 및 정도의 해결은 기대하기 어려우므로 정규화 효과의 도입이 필요하게 된다.

측정오차로 인해 불안정성을 해결하기 위해, 민감도를 이용한 sigmoid함수의 경사도 조정을 통해 정규화 효과를 도입한다. 식 (2.7)을 이용해 민감도를 구하는데, 시스템 변수에 대한 1차 근사한 식을 사용한다. 시스템 변수에 대해 1차 근사된 식의 민감도는 시스템 변수에 무관한 성분을 가지게 되어 신경망의 훈련과정의 반복과정마다 민감도를 새로 구할 필요가 없는 장점이 있다. 신경망의 출력값은 부재별 손상으로 정의 되었으므로, 다음 식과 같이 부재별 민감도를 구한다.

$$\kappa_j = \sqrt{\sum_{i=1}^{m} S_{ij}^2} \tag{2.22}$$

여기서 j는 손상부재로서 1부터 n까지의 값을 갖는다. n과m은 각각 손상부재와 측정변위의 개수를 나타낸다. S는 민감도 행렬이고, κ는 민감도를 각 부재별로 norm을 취한 벡터이다. κ에는 각 부재별로 민감도 정보가 저장되어 있다. 이를

민감도가 큰 부재로 나누어 기준화(normalize)시키면 다음과 같다.

$$\lambda_j = \frac{\kappa_j}{\max \kappa_j} \tag{2.23}$$

이러한 과정을 통하여 가장 큰 민감도를 가진 부재의 경사도가 1이고, 다른 부재는 가장 큰 민감도를 가진 부재의 선형비율로 0과 1사이의 다른 경사도를 가지게 된다. 부재별로 경사도를 다르게 하여 훈련을 하였다면, 검증과정에도 똑같이 부재별로 경사도를 다르게 하여 해를 구한다.

민감도가 큰 부재는 작은 부재들 보다 상대적으로 측정오차에 대해 둔감하게 반응하므로 sigmoid함수의 경사도를 높여 주어서 출력값의 변화량을 높여주고, 반대로 민감도가 작은 부재는 측정오차에 대해 민감하게 반응하므로 sigmoid함수의 경사도를 낮추어서 출력값의 변화량을 낮추게 되어서 오차의 영향을 감소시키게 된다. 이와 같이 민감도에 따른 부재의 sigmoid함수 경사도를 조정을 통하여 정규화 효과를 도입한다.

3.4. 예제

신경망을 이용한 구조물의 손상 평가에서 민감도를 이용해 정규화 효과를 도입하는 예제이다. 2장에서 사용되었던 그림 6의 트러스 구조물로서, 12개의 절점과 25개의 부재로 구성된 구조물이다. 탄성계수는 1000 N/m^{2}이고, 단면적은 상현재의 경우 112.5 cm^2 , 하현재 93.6 cm^2, 수직재 62.5 cm^2,사재 75.0 cm^2 로 2장에

서 사용되었던 예제와 동일하다. 부재를 한정하지 않은 모든 부재를 손상대상 부재로 하고, 그림 7과 같이 하현부 6곳의 절점에서 7개의 측정정보를 얻을 수 있다.

각 하중 단계별 재하 조건은 그림 16에 나타나 있고, 하중의 크기는 N이다. 각 하중 단계별로 측정정보가 7개 이므로, 총 28개의 정보를 얻는다. 모든 부재의 손상정도 값을 구하므로, 출력값의 성분의 개수는 부재 개수와 같은 25개이다. 신경망에서 입력성분이 개수가 출력성분의 개수보다 많을 때 안정적인 패턴의 분류가 가능하므로, 하중 재하 조건을 늘려서 측정변위 정보의 개수를 증가시켰다. 즉, 이 예제는 측정정보가 시스템 변수의 수보다 많은 문제이다.

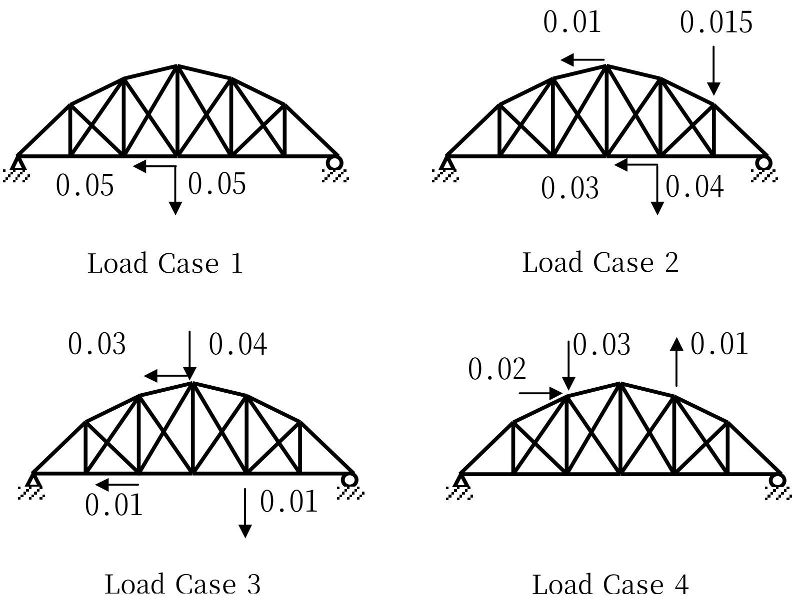

그림 16. 3장 예제의 단계별 작용하중

측정정보가 충분하지만, 역해석 문제에서 불안정성문제를 발생시키는 또 다른 원인은 측정오차 이다. 검증하고자 하는 측정변위에 오차가 포함되어 있을 경우, 부재별 민감도를 이용한 sigmoid함수의 경사도 조정을 통하여 정규화 효과를 도입한다.

이 예제에서는 하나의 부재에서만 손상이 발생한다고 가정한다. 각 부재별로 20%, 50%, 80% 손상이 발생한 경우에 대해 훈련패턴을 정의하여, 총 3×25=75개의 훈련자료를 정하였다. 20%, 50%, 80%의 손상에 대해 훈련 자료를 정한 이유는 손상의 적음, 중간, 많음의 단계로 구분하기 위해서 이다.

신경망의 훈련과정에서 오차의 최소화는 오차역전파 학습법을 사용하였다. 훈련과정에서 학습률은 0.7을 사용하였고, 모멘텀 상수는 0.5를 사용하였다. 반복 연산은 50000번을 최대값으로 하여, 상대오차가 0.1%일 경우 반복연산이 끝나도록 하였다.

훈련이 완료된 후, 신경망에 대한 검토를 위해 신경망의 훈련과정에서는 사용되지 않았지만, 출력의 정해를 알고 있는 측정변위를 이용하여 검증한다. 검증하고자 하는 측정정보에는 계측과정에서의 오차를 고려하여 5%의 오차를 삽입하였다. 민감도가 가장 큰 부재인 9번 부재가 70%의 손상이 발생한 경우와, 민감도가 작은 20번과 21번의 부재에 70% 손상이 발생한 측정변위에 5%의 측정오차가 있는 경우, 신경망의 출력값을 검토한다. 그림 6에서 보듯이 민감도가 큰 9번 부재는 구조물 중앙 부분의 하현재이고, 민감도가 작은 20번과 21번 부재는 중앙 부분의 사재이다.

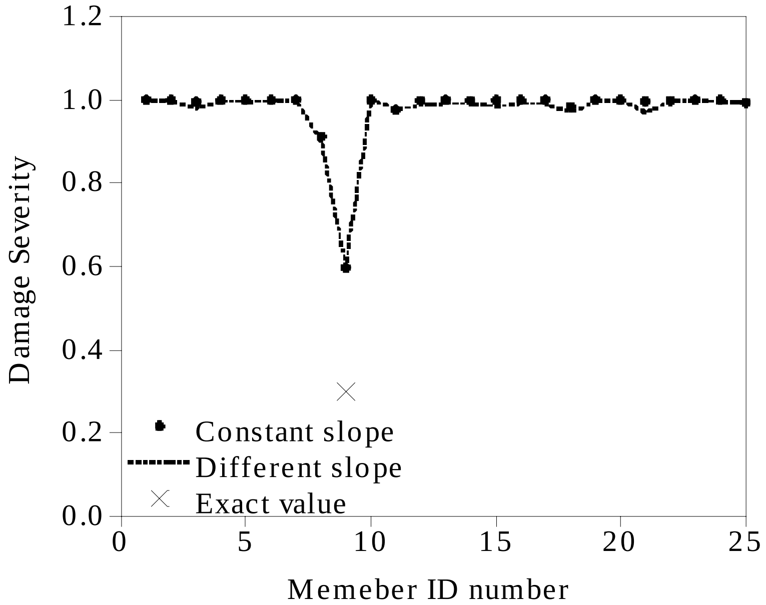

그림 17. 9번 부재 70%손상 경우 검증결과

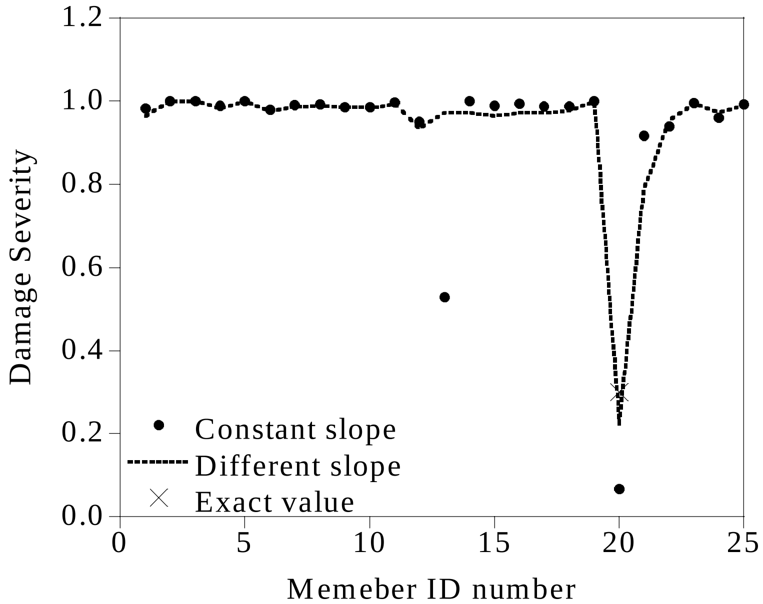

그림 18. 20번 부재 70%손상 경우 검증결과

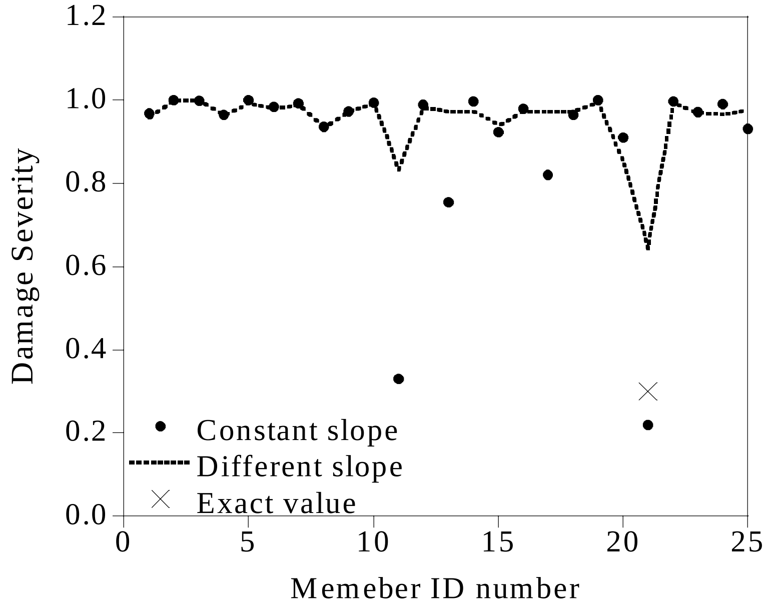

그림 19. 21번 부재 70%손상 경우 검증결과

그림 17은 민감도가 가장 큰 부재인 9번 부재에 70% 손상이 발생한 경우의 측정변위에 대한 신경망의 출력 결과이다. 민감도가 큰 부재이므로 측정오차에 대해 영향을 거의 받지 않아서, 일정한 경사도를 사용한 경우나 부재별 민감도에 따라 sigmoid함수의 경사도를 다르게 사용한 경우의 결과가 비슷하다.

그림 18과 19는 민감도가 작은 사재에서 손상이 발생한 경우의 검증결과 이다. 그림 18은 20번 부재에 70% 손상이 발생한 경우이다. 일정한 경사도를 사용한 결과는 두 개의 부재(13번과 20번)에서 손상이 발생한 것으로 출력이 되었지만, 민감도에 따라 다른 경사도를 사용한 경우에는 실제 손상 부재인 20번 부재의 손상위치를 정확히 탐지하였고, 손상정도 또한 거의 정해와 가깝다.

그림 19는 21번 부재에 70% 손상이 발생한 경우의 검증결과로서, 일정한 경사도를 사용한 경우의 출력값은 해의 진동이 발생하여 손상의 위치 및 정도에 관한 정확한 정보를 주지 못하고 있다. 이에 비하여 민감도에 따라 다른 경사도를 사용한 경우에는 손상의 위치에 관한 정확한 정보를 주고 있다.

그림 17부터 19의 결과를 비교하면, 민감도가 큰 부재에서 손상이 발생한 경우는 민감도가 작은 부재에서 손상이 발생한 경우에 비해 측정오차의 영향을 거의 받지 않으므로 경사도 조정에 관계 없이 거의 정확한 해를 구할 수 있다. 하지만 민감도가 작은 부재는 측정오차의 영향을 많이 받으므로, 부재별 민감도를 이용해 경사도를 달리 하면 정규화 효과를 볼 수 있어 정확해 손상 탐지를 할 수 있다.

4. 결론

역해석 문제로 정의되는 구조물의 손상탐지 기법에서는 측정치의 부족과 측정오차로 인한 불안정성 문제를 해결하기 위해 정규화 기법이 필요하다. 이 논문에서는 신경망을 이용한 구조물의 손상탐지 기법에서 민감도를 이용해 정규화 효과를 도입하는 방법을 제안하였다.

먼저 계산변위와 측정변위의 차이에 대한 최소자승 오차함수의 최적화를 신경망에서 사용되는 오차역전파 학습법을 이용하여 수행하고, 이를 정규화를 이용한 Newton-Raphson 방법과 비교한다. 계산변위는 수학적 모델을 시스템 변수에 대해 Taylor근사한 값을 이용하여 구하고, 이를 이용해 근사 최소자승 오차함수를 정의한다. 시스템 변수에 대한 근사식을 사용하면 implicit nonlinear optimization이 explicit nonlinear optimization문제로 변환되어 수치연산의 효율성을 높일 수 있다.

오차역전파 학습법을 이용한 최적화 과정에서 측정변위별 민감도를 이용한다. 오차역전파 학습법에서 sigmoid함수가 활성화 함수로 사용되는데, 민감도가 큰 측정정보는 다른 측정정보에 비해 상대적으로 오차에 대해 sigmoid함수의 경사도를 높여주고, 오차에 대해 영향을 많이 받는 민감도가 작은 측정정보는 경사도를 낮추어서 오차의 영향을 줄인다. 이 결과를 정규화를 이용한 Newton-Raphson 방법의 결과와 비교하여 정규화 효과를 검증한다.

근사 최소자승 오차함수의 최적화 과정에서 증명된 sigmoid함수의 경사도 조정을 통한 오차역전파 학습법의 정규화 효과를 신경망을 이용한 구조물 손상탐지 기법에 적용한다. 정적 변위를 신경망의 입력값으로 사용하고, 부재별 손상정도를 출력값으로 정의한 단층 신경망을 이용한다. 측정변위를 이용한 훈련 및 검증 과정에서 부재별 민감도 정보를 이용해 sigmoid함수의 경사도를 조정한다. 민감도가 큰 부재는 경사도를 크게 하고, 작은 부재는 경사도를 작게 한다. 검증하고자 하는 측정정보에 오차가 포함되어 있을 때, 함수의 경사도 조정을 통해 정규화 효과를 나타낼 수 있다.

신경망에서 사용되는 훈련자료를 구하기 위해 실제 계측할 수 있지만, 현실적으로는 수치적 계산에 의해 구해야 하므로 수학적 모델이 필요하다. 수학적 모델을 알고 있을 때 민감도를 쉽게 구할 수 있으므로, 이를 이용하면 신경망을 용한 구조물의 손상탐지 기법에서 측정오차에 의한 해의 불안정성을 해결하는데 이용될 수 있다.

참고문헌

김병진97

김병진, “ 다단계 민감도 분석및 인공 신경망을 이용한 구조물 손상 평가 기법” ,공학석사학위논문, 연세대학교, 서울, 1997

김성곤96

김성곤, “ 구조물 손상발견을 위한 신호처리 기법” , 대한 토목학회 논문집, 16(I-1), 1996, pp. 81-92

박현우02

박현우, “ 구조물의 손상진단을 위한 SI기법에서의 정규화 기법” , 공학박사학위논문, 서울대학교, 서울, 2002

Man02

Manolis, P., and Nikos, D.L., “Reliability-based structural optimization using neural networks and Monte Carlo simulation”, *Computer Methods in Applied Mechanics and Engineering*, Volume 191, Issue 32, 7 June 2002, Pages 3491-3507

Pan95

Pandey, P. C., and Barai, S. V., “Multilayer perceptron in damage detection of bridge structures”**,** *Computers & Structures*, Volume 54, Issue 4, 17 February 1995, Pages 597-608

Par01

Park,H.W., Shin, S.B., Lee, H.S., "Determination of an optimal regularization factor in system identification with Tikhonov regularization for linear elastic continua." *International Journal for Numerical Methods in Engineering*,Vol. 51, No.10, pp.1211-1230, 2001.8

Sim99

Simon H., *Neural networks*, 2nd ed. Prentice-Hall,1999

Yeo00

Yeo,I.H., Shin,S.B., H.S.Lee., Chang,S.P., "Statistical damage assessment of framed structures from static responses," *Journal of Engineering Mechanics, ASCE*, Vol. 126, No. 4, pp. 414-421, 2000.4

Yun00

Yun,C.B., Bahng,E.Y., “Substructural identification using neural networks”, *Computers & Structures*, Volume 77, Issue 1, 1 June 2000, Pages 41-52

Yun01

Yun,C.B., Bahng,E.Y., “Joint assessment of framed structures using a neural networks technique, *Engineering Structures*, Volume 23, Issue 5, May 2001, Pages 425-435

Zen01

Zenon, W., and Leonard Z., “Neural networks in mechanics of structures and materials”, *Computers & Structures*, Volume 79, Issues 22-25, September 2001, Pages 2261-2276

Zub02

Zubaydi, A., Haddara, M. R., and Swamidas, A. S. J., “Damage identification in a ship's structure using neural networks”, *Ocean Engineering*, Volume 29, Issue 10, August 2002, Pages 1187-1200

ABSTRACT

Structural damage detection scheme is defined by inverse problem. In inverse problem, regularization techniques must be adopted to avoid ill-posedness which is characterized by sparseness of measurements and noise in measurements. In this paper, it is proposed how regularization effect is introduced to structural damage detection scheme using neural network.

Objective function is defined by least squared error between measured displacements and calculated displacements obtained by numerical model approximated to system parameter. The results, the outputs from optimization of objective function using Newton-Raphson and error back propagation, are compared. In optimization using error back propagation, regularization effect is introduced by changing slope of sigmoid function, which is one of activation functions, according to sensitivity of measurement displacement.

Similarly, regularization effect in structural damage detection scheme using neural network is introduced by changing slope of sigmoid function according to sensitivity of member. The validity of the proposed method is presented by examples.

Key Word

neural network, error back propagation, damage detection, regularization, sensitivity, sigmoid function, truncated least squared error

Student number : 2001-21185

감사의 글

대학원에 입학해서 2년 동안 후회도 많고 아쉬움도 많이 남지만, 내 자신이 어떤 분야에 대해 연구를 하고 그 결실로 한편의 논문을 남기게 되니 매우 기쁩니다. 어찌 보면 이 감사의 글을 쓰기 위해 2년 동안 달려왔다는 생각이 드는군요. 무엇인가를 끝낸다는 것은 또 다른 시작이라고 말하듯이, 지금 끝자락에서 느끼는 아쉬움을 새로운 시작에서의 초심으로 삼고 싶습니다.

너무나도 부족함이 많았기에 감사 드릴 사람도 많군요. 먼저 수 많은 꾸지람과 격려를 통해 논문에 대한 방향을 제시해 주시고, 조언을 아끼지 않으신 이해성 교수님께 진정 감사 드립니다. 그리고 수업을 통해 논문에 대한 배경 지식을 쌓게 해주신 장승필 교수님, 고현무 교수님, 오병환 교수님, 김재관 교수님께도 감사를 드립니다.

논문에 대해 결정적인 아이디어를 제시해 준 현우형과 언제나 논문에 대한 자문을 해주고 세심하게 신경을 써준 기석이형에게 고맙다는 말을 전합니다. 두 형들은 작년 부산사건을 통해 우리 연구실에 길이 남을 에피소드를 남겨주셨군요. 비운의 천재이자 대식가로 구박 받지만 웃음을 잃지 않는 양광에게 고맙다는 말을 전합니다. 언젠가는 양광이가 백조가 될 거라 믿습니다. 그리고 타국에서 고생하면서도 저희들을 챙겨주신 틴틴윈 누나에게 감사 드리고, 올해 논문에 대한 좋은 결과가 있길 바랍니다.

연구실에는 투덜이로 통했지만 남들을 배려할 줄 알았던 남규, 얌전하지만

가끔씩 던지는 한마디에 다른 사람들을 경악시켰던 만우에게 2년 동안 고생 많이 했다는 말과 새로운 직장생활에서도 건투를 빕니다.

입학은 같이 했지만 이제 제 논문을 이어받을 정희와 많이 신경을 써 주지 못해서 항상 미안한 후배들인 재형, 창현, 호영, 승근에게 1년 동안 좋은 논문을 쓰고 졸업하길 빈다고 말을 전하고 싶군요.

마지막으로 1년동안 같은 연구실에서 동고동락했던 용한형, 주성, 정진, 규철, 병규와 졸업 선배님들이신 인호형, 대환형, 윤석형, 경남누나, 문성형, 천종형, 종승형, 한도형, 문구형, 종명에게도 감사 드립니다.

항상 마지막에서 되돌아 볼 때, 아쉬움과 미안함이 많이 남는 것은 어쩔수 없는 인간의 본성인가 봅니다. 28년 동안 언제나 저를 믿고 뒷바라지 해주신 부모님과 가족들에게 사랑한다는 말과 함께 이 논문을 바칩니다.