

# 인공 신경망을 이용한 광대역 과정의 피로 손상 모델 개발

김호성·안인규·김유일<sup>†</sup>  
인하대학교 공과대학 조선해양공학과

## Development of a Fatigue Damage Model of Wideband Process using an Artificial Neural Network

Hosoung Kim·In-Gyu Ahn·Yooil Kim<sup>†</sup>  
Department of Naval Architecture and Ocean Engineering, College of Engineering, Inha University

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

For the frequency-domain spectral fatigue analysis, the probability density function of stress range needs to be estimated based on the stress spectrum only, which is a frequency domain representation of the response. The probability distribution of the stress range of the narrow-band spectrum is known to follow the Rayleigh distribution, however the PDF of wide-band spectrum is difficult to define with clarity due to the complicated fluctuation pattern of spectrum. In this paper, efforts have been made to figure out the links between the probability density function of stress range to the structural response of wide-band Gaussian random process. An artificial neural network scheme, known as one of the most powerful system identification methods, was used to identify the multivariate functional relationship between the idealized wide-band spectrums and resulting probability density functions. To achieve this, the spectrums were idealized as a superposition of two triangles with arbitrary location, height and width, targeting to comprise wide-band spectrum, and the probability density functions were represented by the linear combination of equally spaced Gaussian basis functions. To train the network under supervision, varieties of different wide-band spectrums were assumed and the converged probability density function of the stress range was derived using the rainflow counting method and all these data sets were fed into the three layer perceptron model. This nonlinear least square problem was solved using Levenberg-Marquardt algorithm with regularization term included. It was proven that the network trained using the given data set could reproduce the probability density function of arbitrary wide-band spectrum of two triangles with great success.

**Keywords** : Spectral fatigue analysis(통계적 피로해석), Wideband process(광대역 과정), Probability density function(확률밀도함수), Artificial neural network(인공 신경망), Rainflow counting(레인플로우 집계법), Least square(최소자승법)

## 1. 서론

일반적으로 FPSO와 같은 선박 및 부유식 해양구조물은 구조적으로 복잡한 형상을 가지며 특히 피로 강도 측면에 있어서 취약한 용접 접합부들로 이루어져 있다. 또한 이러한 구조부재들에 풍파, 너울, 바람 그리고 조류 등의 다양한 주파수영역대를 가지는 환경 하중들이 구조물의 운용기간 동안에 중첩되어 작용하게 되어 저 주파수 영역과 고 주파수 영역을 가지는 광대역 다봉형의 응답 스펙트럼을 형성하게 되며 이는 결과적으로 피로 손상에 영향을 미친다. 또한 컨테이너선과 광석운반석등의 대형화와 고속화는 선체 고유 진동 주기를 증가시켜 파랑하중 주기와와의 공

진현상의 발생가능성을 높이게 된다. 이로 인해 스프링잉 및 휘핑 현상이 유발되는데 이 또한 광대역 이봉형의 응력 응답 스펙트럼을 형성하게 되며, 선체 진동 피로를 일으켜 피로강도에 부정적인 영향을 미친다. 따라서 이를 해결하기 위하여 피로 손상 예측 모델 개발 또는 광대역 과정에서의 응력 범위 분포를 예측하는 연구들이 진행되어 왔다.

일반적으로 협대역 과정에서는 응력 응답 스펙트럼에서의 응력 범위의 확률 밀도 함수가 레일리분포의 형태를 따른다고 알려져 있으며 피로 손상 평가가 명백하다. 그러나 비 협대역 과정에서의 응력 범위의 확률밀도함수는 특정한 분포의 형태를 지닌다고 명확히 할 수 없는 단점이 있다. 따라서 비 협대역 과정에서

의 응력 범위의 확률밀도함수를 얻기 위한 방법들이 제시 되었으며, 크게 두 가지 접근법으로 요약이 가능하다. 첫 번째로 시간 이력 데이터에서 직접 집계를 실시 하여 각 응력 범위와 이에 해당하는 수를 구하여 밀도 함수로 나타내는 것이며, 이를 S-N선도와 Miner's Rule에 적용하여 피로 손상도를 구할 수 있다. 이는 시간 영역 해석법이며 가장 정확한 방법이나 시간과 비용의 소비가 큰 단점이 있다. 두 번째로는 주어진 응력 응답 스펙트럼의 통계학적 특성치로 이루어진 피로 손상 예측 모델을 활용하는 방법이다. 이때도 마찬가지로 S-N선도와 Miner's Rule을 활용하여 피로 손상도를 예측할 수 있다. 이 방법은 주파수 영역 해석법이며 시간 영역 해석법에 비하여 쉽고 빠르다는 장점이 있다.

광대역과정에서의 피로손상도를 예측하기 위한 많은 노력이 있었고, 응력 범위의 확률밀도함수를 레일리 분포가 아닌 새로운 확률밀도함수로 가정하는 방법도 제시되었다. Wirsching and Light (1980)는 현대역에서의 피로 손상도에 보정계수를 적용하여 광대역 과정의 피로손상도를 추정하는 방법을 제안하였다. Dirlik (1985)은 광대역 과정의 확률밀도함수를 얻기 위해 레일리 분포와 지수분포함수를 조합한 새로운 형태의 확률밀도함수를 제시하고 이들 확률밀도함수의 파라미터와 응력 스펙트럼의 상관관계를 도출하였다. Jiao and Moan (1990)은 바이모달 스펙트럼에 대한 피로손상도를 추정하기 위해 현대역 기정으로부터 얻어진 피로손상도에 해석적인 방법을 통해 도출된 수정계수를 곱하는 방법을 제안하였다. Zhao and Baker (1992)는 레일리 분포와 와이블 분포를 조합한 새로운 형태의 확률밀도함수를, Benasciutti and Tovo (2005)는 서로 다른 두 개의 레일리 분포를 이용한 확률밀도함수를 제안하고 이를 광대역 과정의 피로손상도 추정에 응용하였다. Kim, et al. (2002)은 인공 신경망 기법을 적용하여 스프링 응답을 하는 선박의 피로손상도를 추정하는 시도를 하였다. Chung, et al. (2012)는 진동 응답하는 8100TEU 급 컨테이너 선박의 피로손상도를 기존에 제시된 다양한 방법들로 계산하고 각 방법론들의 장단점을 분석하였다. Kang (2014)은 인공 신경망을 활용하여 광대역 과정에서의 피로손상모델을 개발하였다. 이때 사용한 스펙트럼은 실제 형상과 유사한 이등변삼각형의 현대역 스펙트럼 2개를 독립적으로 위치시켜 광대역 과정으로 작성하였다. 이봉형 스펙트럼을 나타내기 위해 6가지의 인자를 사용하였으며 이 인자들과 응력범위의 확률 밀도함수를 쌍으로 작성한 후, 인공 신경망을 학습시켜 피로손상 모델을 개발하였다.

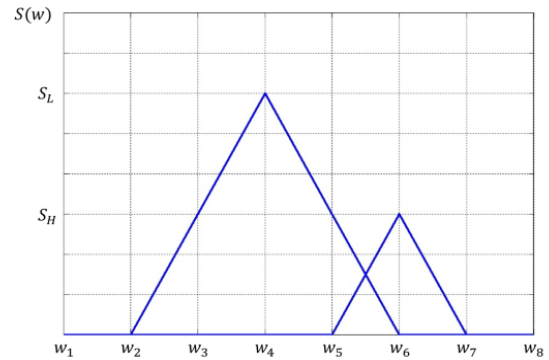
본 논문에서는 Kang (2014)의 연구 결과를 확장하여 이등변 삼각형의 스펙트럼이 독립하지 않고 서로 중첩되는 경우도 포함하여 보다 넓은 광대역 과정까지 확장하는 시도를 하였다. 또한, 응력범위의 확률밀도함수는 가우시안 함수로 근사하여 인공 신경망 학습 자료의 출력 데이터 수를 감소시켰다.

## 2. 응력 스펙트럼

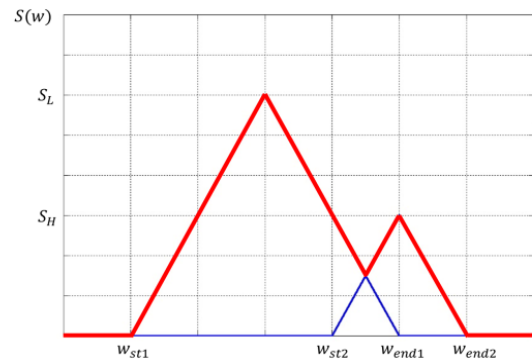
### 2.1 응력 스펙트럼 형상

인공 신경망을 학습시키기 위한 응력 스펙트럼은 총 25,200

개를 작성하였다. 인공 신경망을 학습시키기 위해서는 입력으로 적용되는 응력 스펙트럼을 이산화하고 적절한 파라미터를 이용하여 표현하는 작업이 필요하다. 인공 신경망의 입력자료로 적용되는 응력 스펙트럼의 파라미터는 스펙트럼의 모멘트(spectral moment) 등과 같이 응력 스펙트럼의 형상을 대표할 수 있는 다양한 형태로 결정이 가능하나, 본 연구에서는 비교적 단순한 형태의 광대역 스펙트럼에의 적용성을 우선적으로 검토하기 위해 Fig. 1에 보인 형상과 같이 두 개의 이등변 삼각형의 조합으로 이상화하였다.



(a) Two isosceles triangles



(b) Envelope as a stress spectrum

Fig. 1 Idealized stress spectrum

Table 1 Variables of stress spectrum for the training

Variable	Value
$\omega_{st1}, \omega_{st2}$ [rad/sec]	0, 1.8, 3.6, 5.4, 7.2, 9.0, 10.8, 12.6
$\omega_{end1}, \omega_{end2}$ [rad/sec]	0, 1.8, 3.6, 5.4, 7.2, 9.0, 10.8, 12.6
$m_{c1}, m_{c2}$ [MPa <sup>2</sup> ]	150, 200, 250, 300, 350, 400, 450, 500

스펙트럼을 작성하기 위해 스펙트럼의 x축인 주파수의 시작점 ( $\omega_{st}$ )과 끝점( $\omega_{end}$ ) 2개와 스펙트럼의 면적( $m_c$ )을 추가하여 총 3개의 변수를 사용하여 이등변삼각형 하나를 표현하였으며 2개의 이등변 삼각형을 표현하기 위해 총 6개의 변수를 사용하였다.

Table 1은 인공 신경망의 학습을 위해 사용된 스펙트럼을 표현하기 위해 도입된 6개의 파라미터들의 변화를 요약한 것이다. 응력 스펙트럼의 주파수는 0~12.6 rad/sec의 범위로 정하였고, 스펙트럼의 면적은 150~500까지 50간격으로 변경하였다.

### 3. 확률밀도 함수의 근사

응력 스펙트럼을 시계열로 변환하기 위해 비규칙적(random) 위상각을 생성시켜 역푸리에변환(inverse fourier transform)을 실행하였다. 이는 응력의 시계열이 0의 평균을 가지는 가우시안 분포를 따른다는 가정에 기반한다. 응력 범위의 확률 분포는 응력 시계열의 극치와 관련이 있으므로 확률 분포의 형상은 충분한 길이의 시계열을 확보하지 않으면 쉽게 수렴하지 않는 경향을 띤다. 본 연구에서 적용된 시계열의 총 시간은 50,400초로 설정하여 응력 범위 확률밀도함수가 일정한 형태로 수렴하도록 하였으며, 시계열의 반복이 발생하지 않도록 스펙트럼을 부등간격으로 이산화하고 시계열의 반복성을 자기상관함수를 통해 확인하는

과정을 거쳤다. 시계열의 시간 간격은 불규칙한 시계열 데이터의 피크점을 놓치지 않기 위해 0.1초로 충분히 작게 설정하여 계산하였다. 역푸리에 변환을 실시하여 얻은 시계열 데이터를 레인플로우 집계법을 통해 응력 범위에 대한 이산화된 확률밀도함수로 도출하였으며, 이를 가우시안 함수를 이용하여 근사하였다.

인공 신경망을 학습시킬 때 자료의 수가 신경망의 복잡성 및 수치적 효율성에 많은 영향을 미친다. 이산화된 확률밀도함수를 효과적으로 표현내기 위해서는 x축인 0~250MPa를 40~60개 정도의 충분한 bin으로 분할하여 표현하여야 하는데, 40~60개의 자료를 직접 인공 신경망의 출력 자료로 적용하기에는 자료의 수가 많아져 효율성 측면에 불리한 점을 가진다. 이를 해결하기 위해 확률밀도함수를 가우시안 함수를 기저로 근사하여 인공 신경망의 출력자료 수를 감소시켰다. 비교적 연속적으로 변화하는 확률밀도함수를 식 (1)에 보인, 등간격으로 배치된 다수의 가우시안 기저함수를 통해 근사화 하는 과정을 거쳤다. 최적의 기저함수의 개수는 20개 정도로 편별이 되었는데, 이는 인공 신경망의 출력자료의 개수가 50%이상 감소함을 의미한다.

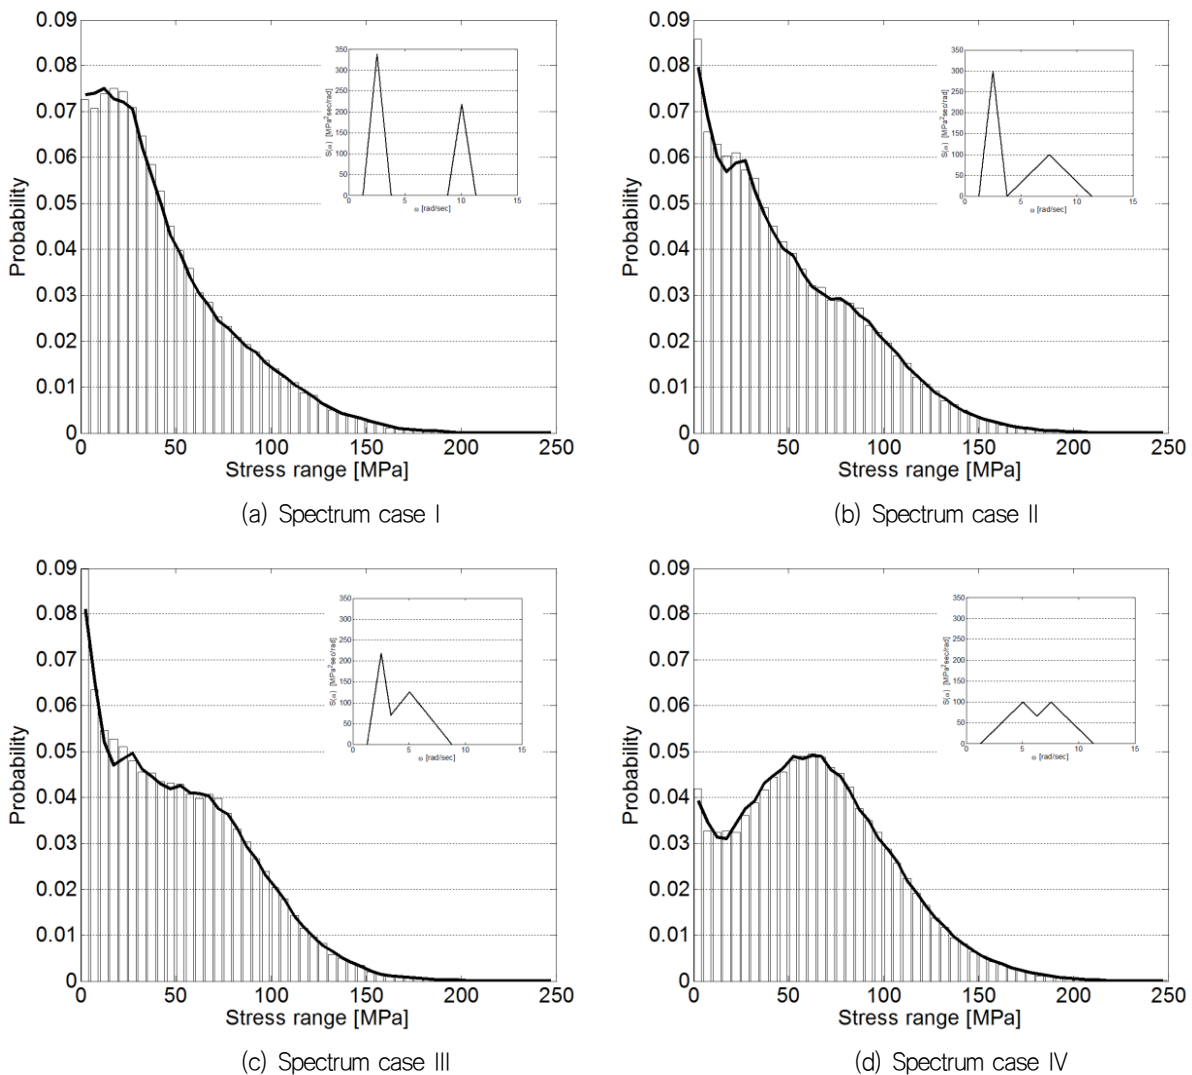


Fig. 2 Discrete probability density function and Gaussian approximation

식 (1)의  $c_n$ 은 출력자료로 사용된 가우시안 함수의 계수이며,  $\Phi_n$ 는 기저함수로 사용된 평균과 분산을 변수로 갖는 가우시안 함수이다.

$$f_s(r) = \sum_{n=1}^L c_n \Phi_n(r) \quad (1)$$

$$\Phi_n(r) = \exp\left[-\frac{(r - n\Delta s)^2}{2(\alpha\Delta s)^2}\right]$$

확률밀도 함수를 가우시안 함수와 같이 국부 근사 기저함수를 적용한 이유는 확률밀도함수의 꼬리부에 해당하는 큰 응력 범위의 경우 그 출현빈도가 매우 작더라도 총 피로손상에 상당한 기여를 하기 때문이다. 상호 직교성을 가지는 Legendre 다항식과 같이 글로벌 기저함수를 사용하는 경우에는 피로손상도가 상대적으로 작을 때 출현빈도가 작고 응력범위가 큰 영역에서의 근사가 어려워 상대적으로 큰 오차를 발생시키는 것을 확인할 수 있었다. 앞에 제시한 Fig. 2는 레인 플로우 집계법으로 얻어진 이산화된 확률밀도함수와 가우시안 기저함수로 근사한 결과를 해당 응력 스펙트럼의 형상과 함께 도시한 그림이다. Fig. 2를 살펴보면 이산화된 확률밀도함수를 막대그래프로 가우시안으로 근사한 값을 실선으로 도시하였으며, 가우시안 기저함수를 기반으로 근사한 결과가 확률밀도함수를 효과적으로 표현하고 있는 것을 알 수 있다.

## 4. 인공 신경망

### 4.1 인공 신경망의 개요

인공 신경망은 시스템의 입력 및 출력 간의 매핑을 통하여 미지의 시스템을 식별할 수 있는 강력한 방법이다. 신경망 이론은 인간의 뇌 또는 신경 시스템의 강력한 대규모 병렬 컴퓨팅 방법을 모방하여 만들어졌으며, 단위 신경 세포 간의 연결 가중치를 조절함으로써 신경회로망을 어떤 특별한 기능을 수행할 수 있도록 학습시킬 수 있다. 이는 물리적인 법칙에 근거하여 시스템의 거동을 수학적으로 표현하고 입력에 대한 출력을 직접적으로 알아내는 방법과 달리 주어진 출력에 입력을 매핑하여 시스템의 특성을 수학적 표현으로 유도해 내는 시스템 식별법의 일종으로 이해가 가능하다.

식별하고자 하는 시스템을 복잡하게 얽힌 네트워크로 구성하고 주어진 입력에 대한 네트워크의 예측치와 주어진 출력간의 오차를 최소화 시킴으로써 네트워크를 구성하는 미지의 파라미터를 결정할 수 있다. 이는 전형적인 비선형 최소화문제 문제로 귀결이 되며 Gauss-Newton법과 같은 2차의 수렴성을 갖는 해법을 통해 최적점을 찾아가는 방법이 일반적으로 적용된다. 인공 신경망은 네트워크 구조에 따라 다양한 형태가 존재하는데 다변수 함수의 근사를 위해 일반적으로 방사형 기저 함수망(radial basis

function network) 또는 다층 퍼셉트론(multilayer perceptron) 등과 같은 신경망 기법들이 사용된다. Rosenblatt (1958)가 제안한 퍼셉트론은 가중치와 입력자료의 곱을 모두 합하여 활성화함수에 의해 판단되는 인공신경망이다. 이후, Marvin and Seymour (1969)는 하나의 조정층으로 이루어진 한계점을 극복하기 위해 3개 또는 그 이상의 층을 갖는 가장 널리 사용되는 다층 퍼셉트론을 제안하였다. 본 연구에서는 이를 이용하여 광대역 응력 응답 스펙트럼에서의 응력 범위의 확률 분포를 구하였다.

### 4.2 다층 퍼셉트론

본 연구에 사용된 인공 신경망인 다층 퍼셉트론은 입력층과 출력층 사이에 하나의 중간층이 존재하는 신경망으로 다음 Fig.3에 도시된 것과 같은 구조를 갖는다. 입력층과 출력층 사이의 중간층을 은닉층이라 하며, 네트워크는 입력층, 은닉층, 출력층의 방향으로 연결되어 있는 전방향 네트워크이다. 대부분의 다층 퍼셉트론은 역전파 알고리즘을 통해 학습시킬 수 있다. 역전파 알고리즘은 반복규칙(chain-rule)을 여러 번 반복 수행하여 출력층에서 발생하는 오차를 역으로 전파하여 진출력값과 네트워크의 예측값을 비교하며 연결강도를 조절하여 오차를 줄여나간다.




Fig. 3 Multilayer perceptron model

식 (2)는 다층 퍼셉트론 모델의 수학적 표현으로 시스템의 출력  $\bar{a}^2$ 가 입력  $\bar{p}$ 와 네트워크 파라미터들의 조합으로 표현되고 있음을 나타내고 있다. 입력과 출력의 상관관계는 일반적으로 비선형적으로 나타나므로 은닉층에 비선형 활성화함수  $f^1$ 을 배치하여 시스템의 비선형성을 구현한다. 비선형 활성화함수의 선택은 다양하나 일반적으로 시그모이드(sigmoidal) 함수가 적용된다.

$$\begin{aligned} \bar{n}^1 &= \overline{W^1 \bar{p}} + \bar{b}^1 \\ \bar{a}^1 &= f^1(\bar{n}^1) = f^1(\overline{W^1 \bar{p}} + \bar{b}^1) \\ \bar{n}^2 &= \overline{W^2 \bar{a}^1} + \bar{B}^2 = \overline{W^2 f^1(\overline{W^1 \bar{p}} + \bar{b}^1)} + \bar{b}^2 \\ \bar{a}^2 &= f^2(\bar{n}^2) = f^2(\overline{W^2 f^1(\overline{W^1 \bar{p}} + \bar{b}^1)} + \bar{b}^2) \end{aligned} \quad (2)$$

식 (3)은 네트워크가 예측하는 시스템의 출력과 진출력 간의 오차를 나타내는 오차함수의 수학적 표현으로, 두 출력값에 대한

제곱오차의 형태를 띠고 있다. 여기에서  $a_{n,k}^2$ 와  $t_{n,k}$ 는 시스템의 출력값과 진출력값이고  $\bar{\theta}$ 는 인공신경망에서 사용된 가중치와 역치로 이루어진 값이다. 이때 시스템은 오차와 가중치와 역치의 합이 가장 작은 값으로 이루어진 네트워크를 구축한다.

$$E(\bar{\theta}) = \sum_{n=1}^M |\bar{r}_n|^2 = \sum_{n=1}^M \sum_{k=1}^{N_{OUT}} (a_{n,k}^2 - t_{n,k})^2 + \lambda |\bar{\theta}|^2 \quad (3)$$

$$\bar{\theta} = [W^1 \ W^2 \ b^1 \ b^2]$$

### 4.3 인공 신경망 적용

응력 스펙트럼을 표현하기 위한 입력자료와 응력 범위 확률밀도함수를 가우시안 함수로 근사한 출력자료 25,200쌍의 데이터를 준비하여 인공 신경망을 학습시켰다. 입력한 데이터쌍을 학습을 위한 데이터(training set)와 성능평가를 위한 데이터(test set)로 분류한 후, 학습 데이터를 통해 네트워크 파라미터를 최적화시키고 성능평가 데이터를 통하여 오차의 증감을 평가해 나가며 네트워크 파라미터를 결정하였다. 아래의 Fig. 4는 네트워크의 학습이 진행되는 동안 감소하는 평균제곱오차(mean square error)를 도시한 것이다. 오차의 최소화에 적용된 알고리즘은 전통적인 Gauss-Newton법을 수정한 Levenberg-Marquadt법으로 경사하강법과 Gauss-Newton법을 혼합하여 수렴의 속도를 극대화 시킨 방법이다. LM법의 2차 수렴성으로 인해 Fig. 4에 보인 바와 같이 평균제곱오차의 값이 빠르게 감소함을 알 수 있다.




Fig. 4 Evolution of mean square error

인공 신경망에서 학습된 시스템의 성능을 확인하기 위해 평균 제곱오차 외에 회귀분석을 통해 결과를 분석하였다. Fig. 5는 레인플로우 집계법으로 도출된 응력 범위 확률밀도함수의 가우시안 함수 계수인 목표자료와 인공 신경망으로 학습된 출력자료를 비교하여 도시한 것이다. 인공 신경망 학습 및 성능 평가에 적용

된 모든 데이터 쌍에 대해 네트워크가 예측한 값(output)과 진출력(target) 간에 높은 상관관계가 있음을 확인할 수 있다. 두 데이터 간의 상관관계는  $Y=X$ 의 직선상에 집중되어 있으며 신뢰도 값 또한 0.99942로 매우 정확한 결과를 얻을 수 있음을 확인하였다. 평균제곱오차는  $5.2641e-007$ 에 수렴하였고, 회귀분석의 R값 역시 1에 매우 가까운 결과를 도출하여 학습된 시스템은 높은 신뢰성을 보이는 것으로 판단할 수 있다.




Fig. 5 Regression results (R=0.99942)


## 5. 비교 및 검증

인공 신경망의 성능을 검증하기 위해 네트워크를 학습시키기 위해 입력된 데이터 범위에 포함되지 않는 448개의 새로운 입력 자료를 시스템에 입력하였다. Table 3은 네트워크 검증을 위해 새로이 준비된 응력 스펙트럼의 파라미터를 나타낸다.


Table 2 Variables of stress spectrum for the validation

Variable	Value
$\omega_{st}$ [rad/sec]	1.25, 3.77, 6.28, 8.80, 11.31
$\omega_{end}$ [rad/sec]	1.25, 3.77, 6.28, 8.80, 11.31
$m_c$ [MPa <sup>2</sup> ]	275, 375, 425, 475


학습된 신경망에 448개의 입력자료를 대입하여 시계열에서 구한 응력 범위 확률밀도함수와 인공 신경망으로 구한 응력범위 확률밀도함수를 비교하였다. Fig. 6은 서로 다른 4개의 응력 스펙트럼에 대한 진출력 확률밀도함수와 네트워크가 예측한 확률밀도함수를 비교한 그림이다. 그림에서 보는 바와 같이 네트워크가 예측한 확률밀도함수가 학습에 사용된 진출력 확률밀도함수를 매우 높은 정도로 예측하고 있음을 확인할 수 있다.




(a) Target PDF - Case I



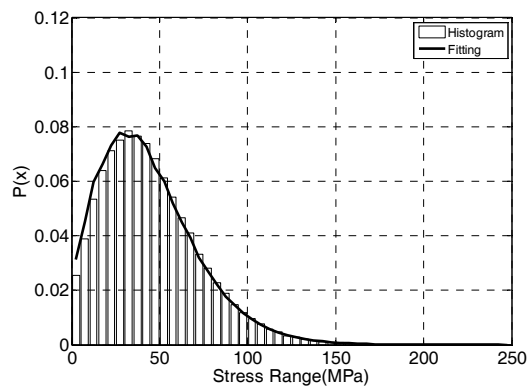
(b) Prediction PDF - Case I




(c) Target PDF - Case II




(d) Predicted PDF - Case I




(e) Target PDF - Case III



(f) Predicted PDF - Case III



(g) Target PDF - Case IV



(h) Predicted PDF - Case IV

Fig. 6 Comparison of probability density function

응력 스펙트럼을 역푸리에 변환하여 얻은 시계열 데이터로 계산된 피로손상도를 정해로 가정한 후, 인공 신경망으로부터 계산된 피로손상도를 정규화하여 본 연구에서 개발된 방법론의 정확도를 평가하였다. 정규화된 피로손상도(normalized fatigue damage)는 식(4)와 같이 계산하였다.

$$NFD_{ANN} = \frac{D_{ANN}}{D_{RFC}} \quad (4)$$

여기서,  $D_{ANN}$ 은 인공 신경망으로 계산된 피로손상도이고,  $D_{RFC}$ 는 레인플로우 집계법을 통해 계산된 피로손상도이며,  $NFD_{ANN}$ 이 1에 가까울수록 정해와 유사함을 의미한다.

Fig. 7(a)는 피로손상도의 절대적 크기를 기준으로 결과를 도시한 것이고 Fig. 7(b)는 응력 스펙트럼의 광대역의 척도인 Vanmarcke Bandwidth Parameter (Wirsching, et al., 1995)를 기준으로 결과를 도시한 것이다. Fig. 7에서 보는 바와 같이 피로손상비가 오차범위  $\pm 10\%$ 의 우수한 결과를 얻었다.

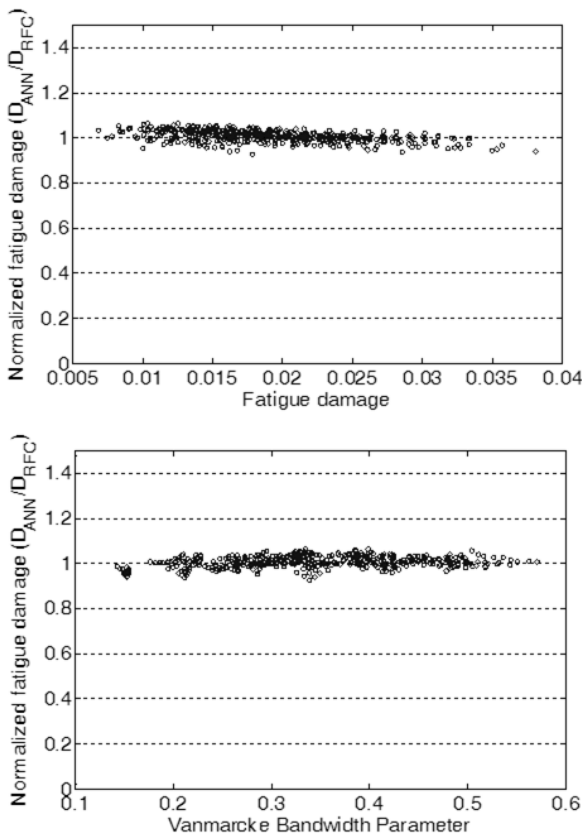


Fig. 7 Normalized fatigue damage

본 모델의 검증을 위해 인공 신경망을 이용하여 구한 피로손상비와 Wirsching-Light에 의해 제안된 방법 (Wirsching and Light, 1980) 통해 얻어진 피로손상비를 비교하였다. Fig. 8에서 보는 바와 같이 WL법은 Vanmarcke bandwidth parameter가 커

질수록 피로손상도의 오차가 증가해 나감을 확인할 수 있으며, 본 연구에서 제안된 방법론이 WL의 방법에 비해 상대적으로 우수한 성능을 보임을 확인할 수 있다.

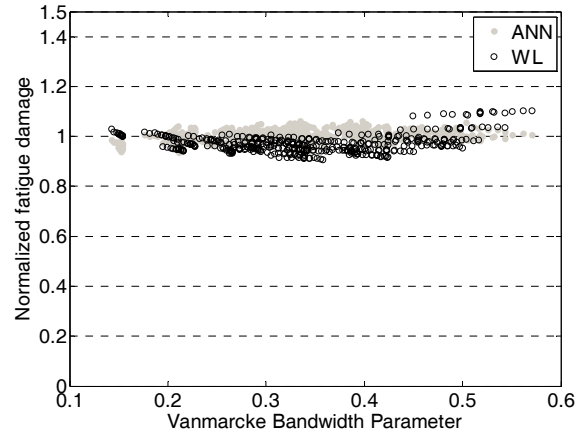


Fig. 8 Comparison with Wirsching-Light model

## 6. 결론

본 연구에서는 두 개의 이등변 삼각형의 중점으로 이상화된 광대역 응력 스펙트럼을 갖는 광대역 과정의 피로손상도를 계산하기 위해 인공 신경망 기법을 적용하여 주어진 광대역 응력 스펙트럼에 해당하는 응력 범위의 확률밀도함수를 도출하는 피로손상모델을 개발하였다.

응력 스펙트럼을 작성한 후 역푸리에 변환하여 시계열 자료를 얻었으며 이를 레인플로우 집계법으로 각 스펙트럼에 해당하는 응력 범위 확률밀도함수를 구하여 인공 신경망의 학습자료로 이용하였다. 시계열에서 얻은 25,200쌍의 응력 스펙트럼과 응력 범위 확률밀도함수를 정해로 가정하여 인공 신경망을 학습시켜 네트워크 예측값과 진출력의 평균 제곱오차를 최소화하는 방법으로 네트워크 파라미터를 결정하였다. 그 결과 평균제곱오차는  $5.2641e-007$ 의 값에 수렴하였고, 회귀분석의 R값은 0.99942로 도출되어 네트워크의 우수한 성능을 확인하였다. 학습에 적용된 데이터와 중복되지 않는 448개의 새로운 스펙트럼을 작성하여 학습된 신경망에 대한 검증을 실행하였다. 신경망이 도출한 피로손상도와 레인플로우 집계법을 통해 구한 피로손상도를 비교한 결과 오차범위  $\pm 10\%$ 의 우수한 성능을 보였으며, Vanmarcke bandwidth parameter에 영향을 받지 않고 항상 일정한 값이 도출됨을 확인하였다.

향후 임의의 형상을 가지는 광대역 스펙트럼을 다루기 위해 스펙트럴 모멘트를 입력 자료로 이용한 네트워크를 구성하여 임의의 형상을 가지는 응력 스펙트럼이 주어지더라도 신뢰성 높은 응력 범위의 확률밀도함수를 도출해내는 인공 신경망을 작성하여 실 설계에 직접 적용 가능한 피로손상모델개발을 위한 연구를 진행할 것이다. 또한, 수학적으로 표현된 네트워크 모델을 급수


전개 등을 이용해 단순화하여 응력 스펙트럼과 확률밀도함수 간의 관계식을 도출할 계획이다.

## 후 기

본 연구는 산업통상자원부 해양플랜트특성화대학사업 및 KEIT의 산업융합원천기술개발사업(10045212, 해양플랜트 통합 운영 및 유지보수를 위한 예지보전 시스템 개발)과 2014년도 인하대학교의 연구 지원을 받아 수행되었습니다. 연구 지원에 감사드립니다.

## References

- Benasciutti, D. & Tovo, R., 2005. Spectral Methods for Life Time Prediction Under Wide Band Stationary Random Processes. *International Journal of Fatigue*, 27(8), pp.876–877.
- Dirlik, T., 1985. *Application of computers in fatigue analysis*. PhD. Thesis, University of Warwick.
- Jiao, G. & Moan, T., 1990. Probabilistic Analysis of Fatigue due to Gaussian Load Processes. *Probabilistic Engineering Mechanics*, 5(2), pp.76–83.
- Choung, J.M. Kim, K.S. Nam, J.M. Koo, J.B. Kim, M.S. Shim, Y.L. & Urm, H.S., 2012. Study on Applicability of Frequency Domain-based Fatigue Analysis for Wide Band Gaussian Process II : Wide Band Prediction Models. *Journal of the Society of Naval Architects of Korea*, 49(4), pp.359–366
- Kang, B.H., 2014. *Development of Fatigue Damage Model of Wide-band process by Artificial Neural Network*. MD. dissertation. INHA University.
- Kim, P.Y. Park, J. Choi, B.K. & Kim, O.H., 2002. Fatigue life calculation for a ship subjected to hull girder vibration. *12th International Offshore and Polar Engineering Conference*, Kitakyushu, Japan, 26–31 May 2002, 584–590.
- Marvin, M. & Seymour, P., 1969. *Perceptrons: An Introduction to Computational Geometry*. MIT Press: Cambridge Mass.
- Rosenblatt, F., 1958. The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain. *Cornell Aeronautical Laboratory, Psychological Review*, 65(6), pp.386–408.
- Wirsching, P.H. & Light M. C., 1980. Fatigue under wide band random stresses. *Journal of the Structural Division*, 106(7), pp.1593–1607.
- Wirsching, P.H. Paez, T.L. & Ortiz, K., 1995. *Random Vibrations Theory and Practice*. Dover Publications: New York.
- Zhao, W. & Baker, M.J., 1992. On the probability density function of rainflow stress range for stationary Gaussian processes. *International Journal of Fatigue*, 14(2), pp.121–135.



김 호 성

안 인 규

김 유 일