

文章编号: 1007-7294(2025)01-0085-13

基于神经网络模型的宽带非高斯 随机过程疲劳损伤分析

袁奎霖, 彭士凤

(大连理工大学 工业装备结构分析国家重点实验室 船舶工程学院, 辽宁 大连 116024)

摘要: 对于遭受各种随机环境载荷的海洋结构物而言, 在设计阶段对其进行疲劳损伤评估尤为重要。海洋结构物的响应经常呈现出宽带特性和非高斯统计特征。因此, 本文提出一种基于神经网络模型的宽带非高斯随机过程疲劳损伤评估方法。采用多种功率谱与不同带宽参数、 $S-N$ 曲线斜率参数以及非高斯过程偏度与峰度的组合对所提出的神经网络模型进行训练和测试。分析输入层神经元、隐藏层神经元个数以及隐藏层层数对模型预报精度的影响, 确定最优的神经网络结构。以时域雨流计数法计算的疲劳损伤结果作为基准, 采用真实双模态功率谱进行数值试验, 并与多种频域疲劳损伤分析方法进行比较, 证明本文所建立的神经网络模型具有更好的准确性和鲁棒性。

关键词: 神经网络; 宽带非高斯过程; 疲劳损伤; 雨流计数法

中图分类号: O346.2 文献标识码: A doi: 10.3969/j.issn.1007-7294.2025.01.009

Fatigue damage assessment of wide-band non-Gaussian random processes based on neural network model

YUAN Kui-lin, PENG Shi-feng

(State Key Lab of Structural Analysis for Industrial Equipment, School of Naval Architecture,
Dalian University of Technology, Dalian 116024, China)

Abstract: Fatigue damage assessment for marine structures subjected to various random environmental loadings is an important issue at the design stage. In many situations, the responses of marine structures present wide-band and non-Gaussian properties. In this paper, a neural network model was developed to predict the fatigue damage caused by wide-band non-Gaussian random processes. Many power spectra with different values of bandwidth parameters, inverse slope of the $S-N$ curve, and skewness and kurtosis of non-Gaussian processes were used to train and validate the developed neural network model. In order to determine the optimal neural network structure, the effects of input neurons, the numbers of hidden layer neurons and hidden layers on the prediction accuracy were investigated. Through case studies with realistic bimodal spectra, by taking the fatigue damage estimated by time-domain rain-flow counting method as reference, it is demonstrated that the developed neural network model is more accurate and robust than the existing frequency-domain methods for fatigue damage assessment of wide-band non-Gaussian random processes.

Key words: neural network; wide-band non-Gaussian process; fatigue damage; rainflow cycle counting

收稿日期: 2024-07-24

基金项目: 国家自然科学基金资助项目(52001058)

作者简介: 袁奎霖(1987-), 男, 博士, 讲师, 通讯作者, E-mail: yuan_kuilin@dlut.edu.cn;

彭士凤(1998-), 女, 硕士研究生。

0 引言

船舶与海洋工程结构物在服役期间会遭受风载荷、波浪载荷、海流载荷等多种随机环境载荷作用,疲劳损伤破坏是其结构失效的一种主要模式。目前,疲劳损伤评估方法主要分为时域方法和频域方法。基于雨流计数法的时域疲劳损伤评估方法具有计算精度高的优点,但需要较长的应力时程数据,计算量较大,在设计初期难以实现。相比之下,根据结构物响应功率谱计算疲劳损伤的频域方法则更为可行且高效。当结构的应力响应是一个窄带高斯随机过程时,其应力幅值可以认为服从 Rayleigh 分布,疲劳损伤在频域内存在解析解^[1]。然而,对于宽带高斯随机应力过程,采用窄带假设方法计算的疲劳损伤则偏于保守。因此,学者们提出了不同的宽带高斯随机应力疲劳损伤的近似评估方法,其中较为常用的有 Wirsching-Light (WL) 带宽修正系数法^[2]、Dirlik (DK) 雨流幅值概率密度近似模型^[3]以及 Tovo-Benasciutti (TB) 雨流计数损伤近似模型^[4]等。然而,由于多种海洋环境载荷具有明显的非高斯特性,例如风载荷、海浪冲击等^[5],或者海洋结构物自身的系统非线性^[6],都可能导致其结构响应呈现宽带特性和非高斯特征。如果依然采用上述高斯随机过程疲劳损伤频域方法来求解非高斯问题,势必存在较大的计算误差。因此,研究宽带非高斯过程疲劳损伤评估方法具有一定的理论意义和工程应用价值。

目前,关于非高斯随机过程疲劳损伤评估问题,学者们提出了一系列近似方法。Winterstein^[7]通过三阶 Hermite 转换函数建立了非高斯过程与底层高斯过程的映射关系,并且假设变换前后的功率谱密度函数保持不变,从而提出了非高斯修正因子的概念,使用该修正因子对高斯疲劳损伤模型进行修正即可得到非高斯疲劳损伤。需要指出,虽然 Winterstein 非高斯修正因子法计算过程简便,但是其修正因子是基于窄带假设建立的,导致在处理宽带非高斯问题时鲁棒性较差。为此,有学者尝试将 Hermite 变换模型与宽带高斯雨流循环的概率密度函数相结合,直接计算宽带非高斯疲劳损伤。Gao 等^[8]将 Hermite 转换函数与 DK 方法相结合提出了非高斯 DK 方法,但是该方法仅适用于偏度为 0 的非高斯问题。Benasciutti 等^[9]、Ding 等^[10]分别将 Hermite 变换模型与 TB 方法相结合提出了非高斯 TB 方法,将非高斯随机应力过程的雨流计数损伤表示为由一个权重系数 b_{TB} 控制的水平穿越计数法 (LC, Level-crossing Counting) 损伤和范围均值计数法 (RC, Range-mean Counting) 损伤的线性组合。由于非高斯 TB 方法给出了非高斯随机过程雨流幅值-均值的近似联合概率密度函数,因此该方法可以对不同偏度与峰度组合的宽带非高斯应力过程进行分析。然而,非高斯 TB 法中权重系数 b_{TB} 的近似公式仅与带宽参数有关,未曾考虑 $S-N$ 曲线斜率参数、非高斯过程偏度与峰度的影响,当 $S-N$ 曲线斜率参数变大或非高斯特性显著时,该方法的计算误差也随之增大。因此,通过重新建立权重系数 b_{TB} 与带宽参数、 $S-N$ 曲线斜率参数、非高斯过程偏度及峰度之间的非线性关系模型,有望提升非高斯 TB 方法疲劳损伤的预报精度。

近年来,基于数据驱动的机器学习技术越来越受到人们的关注,其中作为机器学习中监督学习的代表之一,人工神经网络具有强大的非线性表达能力,使其在数据预测方面拥有强大的优势。目前,陆续有学者将神经网络算法应用于随机载荷下疲劳损伤预报的相关研究^[11-13]。Kim 等^[11]采用人工神经网络模型对高斯双模态随机过程的雨流幅值概率密度分布进行了预报,进而可以评估不同带宽条件下的疲劳损伤;Durodola 等^[12]采用十二种参数化功率谱模拟生成大量高斯随机过程样本,提出了一种预测随机载荷疲劳损伤的人工神经网络模型,与多种频域方法相比,该神经网络模型具有分析速度快、计算精度高等优点;Sun 等^[13]提出了一种基于高斯 TB 方法的人工神经网络模型对权重系数 b_{TB} 进行预报,从而实现了在不同带宽参数与 $S-N$ 曲线斜率参数条件下的宽带高斯随机过程疲劳损伤的高精度预报。然而,目前基于人工神经网络算法的非高斯随机过程疲劳损伤分析的研究还鲜有报道。

因此,本文提出一种基于非高斯 TB 方法和 BP (back propagation) 神经网络算法的宽带非高斯随机过程疲劳损伤评估方法,探讨不同输入层神经元、隐藏层神经元个数以及隐藏层层数对预报结果精度的影响,确定最优的神经网络结构。采用海洋结构物响应功率谱,以时域雨流计数法计算结果作为基

准,对本文提出的神经网络模型预报精度进行验证。结果表明:该模型具有较强的泛化能力,与以往非高斯频域方法相比,具有更好的准确性和鲁棒性。

1 宽带非高斯随机过程疲劳损伤分析基本理论

1.1 谱矩和带宽参数

设 $X(t)$ 为平稳高斯随机过程,其单边功率谱密度函数为 $S_{XX}(\omega)$,则谱矩定义为

$$\lambda_i = \int_0^{\infty} \omega^i \cdot S_{XX}(\omega) d\omega, i = 0, 1, 2, \dots \tag{1}$$

式中, ω 为角频率,单位为 rad/s。对于高斯随机过程,其平均跨零率 v_0 和平均峰值率 v_p 可由谱矩表示为

$$v_0 = \frac{1}{2\pi} \sqrt{\frac{\lambda_2}{\lambda_0}}, v_p = \frac{1}{2\pi} \sqrt{\frac{\lambda_4}{\lambda_2}} \tag{2}$$

需要指出,对于理想窄带随机过程,平均跨零率 v_0 等于平均峰值率 v_p 。

随机过程的带宽特征常用带宽参数 α_1 和 α_2 进行表征,其定义式与谱矩有关:

$$\alpha_1 = \frac{\lambda_1}{\sqrt{\lambda_0 \lambda_2}}, \alpha_2 = \frac{\lambda_2}{\sqrt{\lambda_0 \lambda_4}} \quad 0 \leq \alpha_1, \alpha_2 \leq 1 \tag{3}$$

当随机过程趋于理想窄带条件时, α_1 和 α_2 趋向于 1,反之则为宽带随机过程。此外,有学者^[14]指出随机过程的导数 $\dot{X}(t)$ 的带宽参数 β_1 和 β_2 与高阶谱矩有关,其定义为

$$\beta_1 = \frac{\lambda_3}{\sqrt{\lambda_2 \lambda_4}}, \beta_2 = \frac{\lambda_4}{\sqrt{\lambda_2 \lambda_6}} \quad 0 \leq \beta_1, \beta_2 \leq 1 \tag{4}$$

1.2 宽带高斯疲劳损伤分析方法

根据 S-N 曲线与 Palmgren-Miner 线性累积损伤理论,随机应力过程在作用时间 T 内的疲劳损伤 D 可表示为

$$D = \frac{v_p \cdot T}{K} \int_0^{\infty} s^m \cdot f_s(s) ds \tag{5}$$

式中, $f_s(s)$ 为应力幅值 s 的概率密度函数, m 和 K 分别是 S-N 曲线中的斜率参数和材料参数。S-N 曲线表达式为 $N = K \cdot s^{-m}$,表示在应力幅值 s 水平下材料发生疲劳破坏所需的应力循环数为 N 。

当随机应力过程为一个零均值高斯窄带过程时,可认为其雨流幅值分布服从 Rayleigh 分布:

$$f_s(s) = \frac{s}{\sigma_X^2} \exp\left(-\frac{s^2}{2\sigma_X^2}\right) \tag{6}$$

式中, $\sigma_X^2 = \lambda_0$ 是随机过程 $X(t)$ 的方差。由式(5)可得到作用时间 T 内基于窄带假设的疲劳损伤解析解:

$$D_{NB} = \frac{v_0 T}{K} (\sqrt{2\lambda_0})^m \Gamma\left(\frac{m}{2} + 1\right) \tag{7}$$

式中, $\Gamma(\cdot)$ 表示 Gamma 函数。然而,当随机应力是一个宽带高斯随机过程时,其雨流幅值的概率密度函数尚不可推导。因此,学者们提出了多种宽带高斯随机过程疲劳损伤的近似评估方法,下面介绍其中的几种。

1.2.1 Wirsching-Light 方法(WL)

Wirsching 和 Light^[2]考虑带宽的影响,提出了一个宽带高斯疲劳损伤的近似估算公式:

$$D_{WL} = \rho_{WL} D_{NB} \tag{8}$$

式中, ρ_{WL} 是带宽修正因子,其表达式为

$$\rho_{WL} = a(m) + [1 - a(m)](1 - \varepsilon)^{b(m)} \tag{9}$$

$$a(m) = 0.926 - 0.033m, b(m) = 1.587m - 2.323 \quad (10)$$

Wirsching 带宽参数 $\varepsilon = \sqrt{1 - \alpha_2^2}$ 。

1.2.2 Dirlik 方法(DK)

Dirlik^[13]提出一个由指数分布和 Rayleigh 分布组成的雨流幅值分布的半经验公式:

$$f_{\text{DK}}(s) = \frac{1}{\sqrt{\lambda_0}} \left[\frac{D_1}{Q} \exp\left(-\frac{Z}{Q}\right) + \frac{D_2 Z}{H^2} \exp\left(-\frac{Z^2}{2H^2}\right) + D_3 Z \exp\left(-\frac{Z^2}{2}\right) \right] \quad (11)$$

式中,

$$Z = \frac{s}{\sqrt{\lambda_0}}, x_m = \frac{\lambda_1}{\lambda_0} \left(\frac{\lambda_2}{\lambda_4} \right)^{1/2}, D_1 = \frac{2(x_m - \alpha_2^2)}{1 + \alpha_2^2}, D_2 = \frac{1 - \alpha_2 - D_1 + D_1^2}{1 - H} \quad (12)$$

$$D_3 = 1 - D_1 - D_2, H = \frac{\alpha_2 - x_m - D_1^2}{1 - \alpha_2 - D_1 + D_1^2}, Q = \frac{1.25(\alpha_2 - D_3 - D_2 H)}{D_1}$$

将式(11)代入式(5)可得到基于 DK 方法的宽带高斯疲劳损伤解:

$$D_{\text{DK}} = \frac{v_p T}{K} (\sqrt{\lambda_0})^m \left[D_1 Q^m \Gamma(1 + m) + (\sqrt{2})^m \Gamma\left(1 + \frac{m}{2}\right) (D_2 |H|^m + D_3) \right] \quad (13)$$

1.2.3 Tovo-Benasciutti 方法(TB)

Rychlik^[15]通过理论分析证明,基于雨流计数法的疲劳损伤总是处于范围均值计数法(RC)和水平穿越计数法(LC)的疲劳损伤之间,即

$$D_{\text{RC}} \leq D_{\text{RFC}} \leq D_{\text{LC}} = D_{\text{NB}} \quad (14)$$

其中, $D_{\text{LC}}=D_{\text{NB}}$ 可根据公式(7)计算, D_{RC} 的近似解如下:

$$D_{\text{RC}} \cong \frac{v_p \cdot T}{K} (2\sqrt{2\lambda_0})^m \alpha_2^m \Gamma\left(1 + \frac{m}{2}\right) = \alpha_2^{m-1} D_{\text{NB}} \quad (15)$$

Tovo 和 Benasciutti^[4]提出了一个雨流计数损伤的近似模型,即

$$D_{\text{RFC}} = b_{\text{TB}} D_{\text{LC}} + (1 - b_{\text{TB}}) D_{\text{RC}} \quad (16)$$

式中, b_{TB} 为权重系数, Tovo 和 Benasciutti 经过大量数值模拟得到 b_{TB} 的近似公式如下:

$$b_{\text{TB}} = \frac{(\alpha_1 - \alpha_2)}{(\alpha_2 - 1)^2} \left\{ (\alpha_1 - \alpha_2) + 1.112 [1 + \alpha_1 \alpha_2 - (\alpha_1 + \alpha_2)] \exp(2.11 \alpha_2) \right\} \quad (17)$$

同样,基于雨流计数法的峰值-谷值联合概率密度函数 $H_{\text{RFC}}(u, v)$, 也可以由范围均值计数法和水平穿越计数法相应的联合概率密度函数 $H_{\text{RC}}(u, v)$ 和 $H_{\text{LC}}(u, v)$ 两者线性组合而成:

$$H_{\text{RFC}}(u, v) = b_{\text{TB}} H_{\text{LC}}(u, v) + (1 - b_{\text{TB}}) H_{\text{RC}}(u, v) \quad (18)$$

上式中的水平穿越计数法的峰值-谷值联合概率分布函数可表示为

$$H_{\text{LC}}(u, v) = \begin{cases} [p_u(u) - p_v(u)] \delta(u+v) + p_v(u) \delta(u-v) & u > 0 \\ p_u(u) \delta(u-v) & u \leq 0 \end{cases} \quad (19)$$

式中, δ 表示 Dirac 函数, $p_u(x)$ 和 $p_v(x)$ 分别表示随机过程峰值和谷值的概率密度函数。对于零均值高斯随机过程, $p_u(x)$ 可表示为

$$p_u(x) = \frac{\sqrt{1 - \alpha_2^2}}{\sqrt{2\pi\lambda_0}} \exp\left[-\frac{x^2}{2\lambda_0(1 - \alpha_2^2)}\right] + \frac{\alpha_2 x}{\lambda_0} \exp\left(-\frac{x^2}{2\lambda_0}\right) \Phi\left(\frac{\alpha_2 x}{\sqrt{(1 - \alpha_2^2)\lambda_0}}\right) \quad (20)$$

式中, $\Phi(\cdot)$ 表示标准高斯分布的累积分布函数。由于峰值与谷值关于零均值对称, 故有 $p_u(x) = p_v(-x)$ 。

此外, 式(18)中的范围均值计数法的峰值-谷值联合概率分布函数可表示为

$$H_{\text{RC}}(u, v) = \frac{1}{\lambda_0 \alpha_2^2 2\sqrt{2\pi}} \exp\left[-\frac{u^2 + v^2}{4\lambda_0(1 - \alpha_2^2)}\right] \cdot \exp\left[-\frac{(u-v)^2(1 - 2\alpha_2^2)}{4\lambda_0(1 - \alpha_2^2)2\alpha_2^2}\right] \left(\frac{u-v}{2\sqrt{(1 - \alpha_2^2)\lambda_0}}\right) \quad (21)$$

1.3 宽带非高斯疲劳损伤分析方法

工程上通常采用三阶和四阶中心距,即偏度 γ_3 和 γ_4 峰度来描述非高斯随机过程 $Z(t)$,其定义为

$$\gamma_3 = \frac{E\left[\left(Z - \mu_z\right)^3\right]}{\sigma_z^3}, \gamma_4 = \frac{E\left[\left(Z - \mu_z\right)^4\right]}{\sigma_z^4} \quad (22)$$

式中, $E[\cdot]$ 表示数学期望, μ_z 和 σ_z 分别是非高斯随机过程 $Z(t)$ 的均值和标准差。偏度 γ_3 反映了概率密度分布相对于其均值的偏斜方向和程度:当 $\gamma_3 > 0$ 时称为右偏,位于均值右侧的累积概率大于均值左侧的累积概率,反之 $\gamma_3 < 0$ 时称为左偏。峰度 γ_4 反映了概率密度分布相对于其均值的集中程度:当 $\gamma_4 > 3$ 时称为软化非高斯过程,其概率密度分布不仅在均值处比正态分布更加陡峭,而且比正态分布在尾部拥有更多极端值,使结构加速产生疲劳。对于高斯随机过程 $X(t)$,其偏度和峰度分别为0和3。已有研究^[8]表明,海洋结构物随机响应的峰度通常小于6,因此本文主要针对峰度 $3 \leq \gamma_4 \leq 6$ 的软化非高斯过程疲劳损伤分析方法进行研究。

对于高斯随机过程 $X(t)$,可以通过引入非线性转换函数 $G(\cdot)$,使其变换为具有指定偏度和峰度的非高斯随机过程 $Z(t)$,即

$$Z(t) = G[X(t)] \leftrightarrow X(t) = g[Z(t)] \quad (23)$$

式中, $g(\cdot)=G^{-1}(\cdot)$ 为逆传递函数,可用来将具有指定偏度和峰度的非高斯随机过程转化成高斯随机过程。目前,应用最为广泛的是由Winterstein^[7]提出的三阶Hermite转换函数,其定义为

$$Z_0 = \frac{Z(t) - \mu_z}{\sigma_z} = G[X_0] = \kappa\left[X_0 + h_3(X_0^2 - 1) + h_4(X_0^3 - 3X_0)\right] \quad (24)$$

式中, $X_0 = \frac{X(t) - \mu_x}{\sigma_x}$, μ_x 和 σ_x 分别为高斯过程 $X(t)$ 的均值和标准差, κ 、 h_3 和 h_4 分别为模型系数。Winterstein等^[16]提出的模型系数 κ 、 h_3 和 h_4 的经验公式如下:

$$\begin{aligned} \kappa &= \frac{1}{\sqrt{1 + 2h_3^2 + 6h_4^2}}, & h_3 &= \frac{\gamma_3}{6} \left[\frac{1 - 0.015|\gamma_3| + 0.3\gamma_3^2}{1 + 0.2(\gamma_4 - 3)} \right] \\ h_4 &= h_{40} \left[1 - \frac{1.43\gamma_3^2}{\gamma_4 - 3} \right]^{1 - 0.1(\gamma_4)^{0.8}}, & h_{40} &= \frac{[1 + 1.25(\gamma_4 - 3)]^{1/3} - 1}{10} \end{aligned} \quad (25)$$

需要指出,采用式(24)和(25)时非高斯过程的偏度和峰度存在以下限制条件,即

$$\gamma_3^2 < \frac{2(\gamma_4 - 3)}{3} \quad (26)$$

由于Hermite转换函数的单调性,非高斯过程与其底层高斯过程的峰值和谷值存在以下关系:

$$\begin{aligned} Z_u &= \mu_z + \sigma_z G\left(\frac{X_u - \mu_x}{\sigma_x}\right) \\ Z_v &= \mu_z + \sigma_z G\left(\frac{X_v - \mu_x}{\sigma_x}\right) \end{aligned} \quad (27)$$

由此,零均值非高斯随机过程的疲劳损伤可表示为

$$D_{NG} = \frac{\nu_p T}{K} \left(\frac{\sigma_z}{2}\right)^m \int_0^\infty [G(s) - G(-s)]^m f_s(s) ds \quad (28)$$

1.3.1 非高斯修正因子法

Winterstein^[7]基于窄带假设和Hermite转换函数,提出了非高斯修正因子,其定义如下:

$$C_{NG}^{WT} = \frac{D_{NG}^{NB}}{D_G^{NB}} \quad (29)$$

式中, D_G^{NB} 和 D_{NG}^{NB} 分别为高斯和非高斯窄带随机过程疲劳损伤,分别根据式(7)和(28)计算。

文中将上述非高斯修正因子与高斯 WL 方法相结合,由式(30)计算宽带非高斯过程疲劳损伤:

$$D_{NG}^{WL} = C_{NG}^{WT} D_{WL} = C_{NG}^{WT} \rho_{WL} D_G^{NB} \tag{30}$$

1.3.2 非高斯 DK 法

将高斯 DK 法雨流幅值概率密度函数,即式(11)代入式(28)即可得到非高斯 DK 法的疲劳损伤^[8]:

$$D_{NG}^{DK} = \frac{v_p T}{K} \left(\frac{\sigma_Z}{2} \right)^m \int_0^\infty [G(s) - G(-s)]^m f_{DK}(s) ds \tag{31}$$

1.3.3 非高斯 TB 法

仿照高斯 TB 法,非高斯 TB 法的疲劳损伤^[9]也可以通过权重系数 b_{TB} 将 LC 法和 RC 法结合在一起得到:

$$D_{NG}^{TB} = b_{TB} D_{NG}^{LC} + (1 - b_{TB}) D_{NG}^{RC} \tag{32}$$

$$\begin{aligned} D_{NG}^{LC} &= \frac{v_p T}{K} \left(\frac{\sigma_Z}{2} \right)^m \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} [G(x_u) - G(x_v)]^m \cdot H_{u,v}^{LC,G}(x_u, x_v) dx_v dx_u \\ &= \frac{v_p T}{K} \left(\frac{\sigma_Z}{2} \right)^m \int_0^{+\infty} [G(x_u) - G(-x_u)]^m \alpha_2 \frac{x_u}{\lambda_0} \exp\left(-\frac{x_u^2}{2\lambda_0}\right) dx_u \end{aligned} \tag{33}$$

$$D_{NG}^{RC} = \frac{v_p T}{K} \left(\frac{\sigma_Z}{2} \right)^m \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} [G(x_u) - G(x_v)]^m \cdot H_{u,v}^{RC,G}(x_u, x_v) dx_v dx_u \tag{34}$$

式中的 $H_{u,v}^{RC,G}(x_u, x_v)$ 已由式(21)给出。需要指出,权重系数 b_{TB} 仍采用高斯 TB 法的近似公式即式(17),未曾考虑 S-N 曲线斜率参数 m 、非高斯过程偏度 γ_3 与峰度 γ_4 的影响。

2 基于神经网络模型的非高斯疲劳损伤分析方法

人工神经网络(artificial neural network, ANN)是一种模拟人体大脑神经网络结构进行信息处理的数学模型。人工神经网络不需要确定输入与输出之间映射关系的具体数学表达式,而是通过对数据样本的学习,训练出一个具有准确学习规则的特定神经网络。其中,BP 神经网络是一种基于误差反向传播算法的多层前馈型神经网络,是目前在疲劳分析领域应用最为广泛的神经网络模型^[11-13]。

2.1 神经网络模型构建

如图 1 所示,本文提出一种基于非高斯 TB 方法和 BP 神经网络模型的宽带非高斯随机过程疲劳损

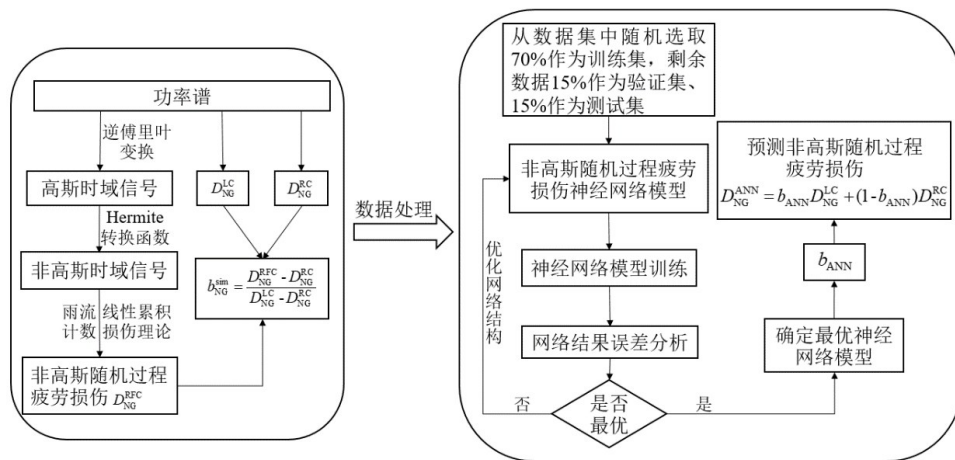


图 1 基于神经网络模型的非高斯随机过程疲劳损伤评估流程图

Fig.1 Flowchart of fatigue damage assessment for non-Gaussian random processes based on neural network model

伤评估方法。该神经网络以带宽参数、S-N曲线斜率参数、非高斯过程偏度和峰度作为输入,以非高斯TB方法对应的权重系数 b_{ANN} 作为输出,再根据式(32)计算疲劳损伤 D_{NG}^{ANN} 。

神经网络的训练需要足够数量的数据样本,数据集的准确性对神经网络预报结果的准确性具有重要的影响。本文根据图2所示的七种参数化功率谱,采用逆傅里叶变换技术模拟生成高斯随机过程时域信号,再通过 Hermite 转换函数将其转化为具有指定偏度和峰度的非高斯随机过程时域信号。针对模拟生成的非高斯随机过程,采用雨流计数法计算疲劳损伤 D_{NG}^{RFC} ,将其根据式(35)转化为对应的权重系数 b_{NG}^{sim} :

$$b_{NG}^{sim} = \frac{D_{NG}^{RFC} - D_{NG}^{RC}}{D_{NG}^{LC} - D_{NG}^{RC}} \tag{35}$$

式中, D_{NG}^{RFC} 为由雨流计数法计算的非高斯随机过程疲劳损伤, D_{NG}^{LC} 和 D_{NG}^{RC} 可参考式(33)和式(34)。

图2(a)~(g)中七种谱型的 ω_1 和 ω_3 为固定值,分别取 $2\pi/1000$ rad/s和 2π rad/s,而 ω_2 介于 ω_1 和 ω_3 之间,通过改变 ω_2 、 h_1 和 h_2 的值可以得到具有不同带宽参数的功率谱。此外,假定偏度和峰度分别为 $0 \leq \gamma_3 \leq 1$ 和 $3 \leq \gamma_4 \leq 6$,S-N曲线的材料参数 $K=1$,斜率参数 $m=3, 4, 5$ 和 6 ,共生成21 000组数据组成数据集,从中随机选取其中70%作为训练集,剩余数据的30%作为验证集和测试集。本文建立的神经网络模型的输入层变量的参数范围如表1所示。

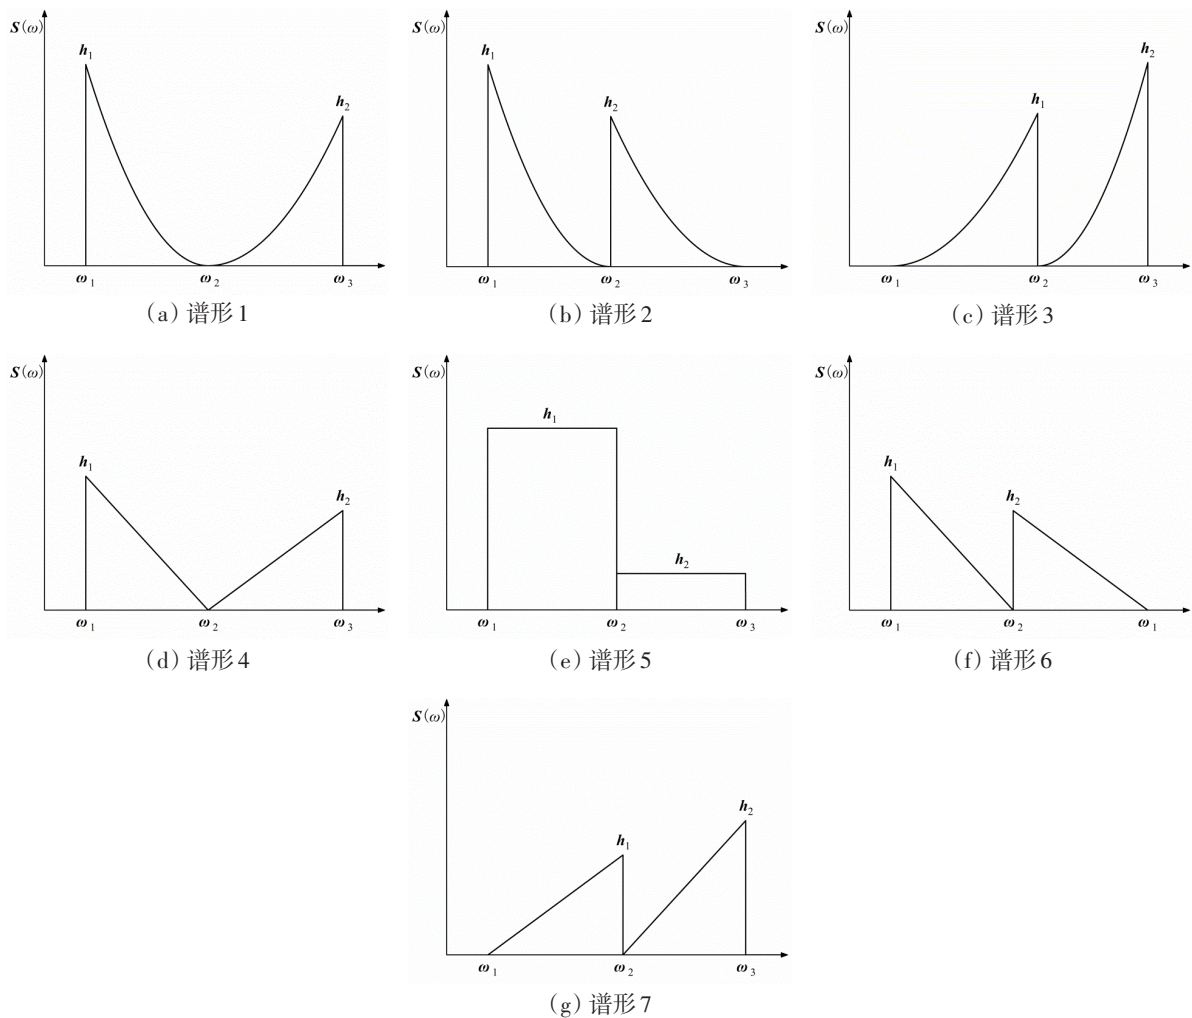


图2 不同形状的参数化功率谱

Fig.2 Illustration of different parametric power spectra

表 1 输入层变量的参数范围

Tab.1 Ranges of variables for input-layer

参数	α_1	α_2	β_1	β_2	m	γ_3	γ_4
最小值	0.28	0.20	0.83	0.67	3	0	3
最大值	0.91	0.70	0.99	0.97	6	1	6

2.2 疲劳损伤评估网络结构优化

神经网络模型具有较强的非线性映射特性,神经元的个数以及隐藏层的层数等网络结构参数,均对模型的预报精度具有明显的影响。因此,本文将从输入层神经元变量选取、单隐藏层神经元个数以及隐藏层层数三个方面进行讨论,以寻找计算精度最高的网络结构,作为非高斯随机过程疲劳损伤预报的神经网络模型结构。

本文采用决定系数 R^2 、相关系数 $R_{X,Y}$ 、误差指数 I 和均方根误差 δ_{RMSE} 四个参数来判断神经网络的预报精度,其定义分别为

$$R^2 = 1 - \frac{\sum (X - Y)^2}{\sum (X - \mu_X)^2}, R_{X,Y} = \frac{E[(X - \mu_X)(Y - \mu_Y)]}{\sigma_X \sigma_Y} \tag{36}$$

$$I = \sqrt{\frac{1}{n} \sum \left[\log_{10} \left(\frac{Y}{X} \right) \right]^2}, \delta_{RMSE} = \sqrt{\frac{1}{n} \sum (X - Y)^2}$$

式中, X 代表时域模拟得到的权重系数 b_{NG}^{sim} , Y 代表神经网络模型预测的权重系数 b_{ANN} 。当 R^2 和 $R_{X,Y}$ 越接近于 1, I 和 δ_{RMSE} 越接近于 0 时,表明模型预报精度越好。

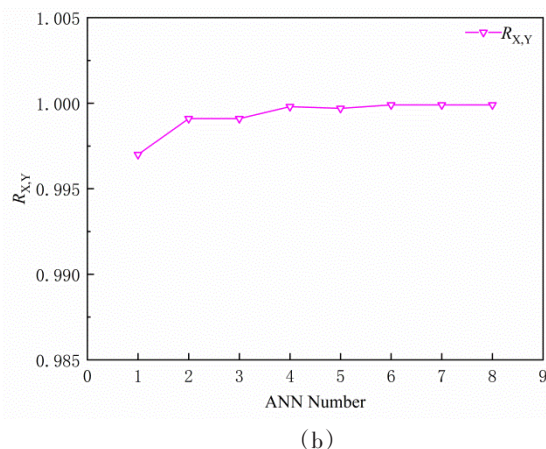

2.2.1 输入层神经元

为了确定最优的神经网络模型,首先需要探讨对于模型输出 b_{ANN} 具有潜在影响的因素。将表 1 中的带宽参数 ($\alpha_1, \alpha_2, \beta_1$ 和 β_2)、S-N 曲线斜率参数 m 和非高斯过程偏度 γ_3 与峰度 γ_4 七个参数进行组合,构建了如表 2 所示的八种神经网络模型。针对已训练完成的不同神经网络模型,将测试集的输出结果与期望结果进行对比,如图 3 所示。可以看出,ANN2 较 ANN1 在预报精度上有明显的提升,表明 S-N 曲

表 2 神经网络模型的输入与输出变量

Tab.2 Input and output variables of the ANN models

ANN 类型	输入元个数	输入元	输出元	ANN 类型	输入元个数	输入元	输出元
ANN 1	2	$\alpha_1 \alpha_2$	b_{ANN}	ANN 5	5	$\alpha_1 \alpha_2 m \gamma_3 \gamma_4$	b_{ANN}
ANN 2	3	$\alpha_1 \alpha_2 m$	b_{ANN}	ANN 6	6	$\alpha_1 \alpha_2 m \gamma_3 \gamma_4 \beta_1$	b_{ANN}
ANN 3	4	$\alpha_1 \alpha_2 m \gamma_3$	b_{ANN}	ANN 7	6	$\alpha_1 \alpha_2 m \gamma_3 \gamma_4 \beta_2$	b_{ANN}
ANN 4	4	$\alpha_1 \alpha_2 m \gamma_4$	b_{ANN}	ANN 8	7	$\alpha_1 \alpha_2 m \gamma_3 \gamma_4 \beta_1 \beta_2$	b_{ANN}






图3 不同输入层神经元组合的比较

Fig.3 Comparison of different combination of input neurons

线斜率参数 m 是权重系数 b_{ANN} 的一个重要影响因素。通过 ANN3 和 ANN4 与 ANN2 比较可知,在神经网络模型中考虑偏度 γ_3 和峰度 γ_4 可进一步提高预报精度,而且峰度 γ_4 比偏度 γ_3 更为重要。此外,与随机过程的导数过程相关的带宽参数 β_1 和 β_2 对权重系数 b_{ANN} 也有一定影响。因此,本文的神经网络模型将选取 ANN8 的输入层神经元。

2.2.2 单隐藏层神经元个数

在BP神经网络中,隐藏层神经元个数对模型预报精度具有明显的影响,当神经元个数过少或者过多时,会出现“欠拟合”或“过拟合”现象。通过改变单隐藏层神经元个数,探讨不同神经元个数对于神经网络模型预报精度的影响,结果如表3所示。可以看出,不同神经元数量对于预报精度有着较为明显的影响,当神经元个数低于28时,计算结果的精度随神经元个数增加而提高;当神经元个数高于28时,计算结果精度反而有所降低。因此,单隐藏层神经元个数确定为28个。

表3 单隐藏层神经元数量对神经网络精度的影响

Tab.3 Effect of different number of neurons in single hidden layer on ANN accuracy

神经元数量	20	22	24	26	28	30	32	34	36
R^2	0.9997	0.9998	0.9998	0.9998	0.9998	0.9998	0.9998	0.9998	0.9998
$R_{X,Y}$	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999
I	0.0047	0.0046	0.0042	0.0042	0.0039	0.0040	0.0044	0.0044	0.0046
δ_{RMSE}	0.0060	0.0058	0.0055	0.0054	0.0051	0.0052	0.0052	0.0054	0.0056

2.2.3 隐藏层层数

隐藏层层数同样对神经网络模型预报精度有着重要影响。如表4所示,分别建立不同隐藏层层数的网络结构,并通过试算确定该隐藏层层数下预报精度达到最高时每层的神经元个数。可以看出,当隐藏层层数为两层、且两层神经元数量分别为18和2时,该网络结构的预报精度最高。

表4 不同隐藏层精度对比

Tab.4 Precision comparison of ANN with different numbers of hidden layers

隐藏层层数(神经元数量)	1(28)	2(18-2)	3(15-5-3)	4(12-8-4-3)
R^2	0.9998	0.9999	0.9998	0.9998
$R_{X,Y}$	0.9999	0.9999	0.9999	0.9999
I	0.0039	0.0016	0.0042	0.0041
δ_{RMSE}	0.0051	0.0012	0.0054	0.0055

综上所述,通过探讨不同输入层神经元、隐藏层神经元个数以及隐藏层层数对预报结果的影响,确定了最优的网络结构,即输入元为 α_1 、 α_2 、 β_1 、 β_2 、 m 、 γ_3 和 γ_4 ,隐藏层数为2(各层神经元数量为18-2),输出为 b_{ANN} 的神经网络模型。因此,后文将基于该模型对非高斯随机过程疲劳损伤进行预报,并以ANN进行表示。

3 算例验证

为了验证所建立的神经网络模型对非高斯疲劳损伤预报结果的准确性,本章选取一个贴近于实际海洋结构物响应的双模态功率谱^[17]进行数值验证,该功率谱表达式如下:

$$S(\omega) = A \frac{7793}{T_w^4 \omega^5} \exp\left(-\frac{1948}{T_w^4 \omega^4}\right) \times \frac{1}{\left[1 - \left(\frac{\omega}{\omega_N}\right)^2\right]^2 + 4\xi^2 \left(\frac{\omega}{\omega_N}\right)^2} \quad (37)$$

式中, A 是用于调整零阶谱矩为1的比例因子, $T_w=2\pi/\omega_w$ 表示海浪周期, $\omega_N=2\pi/T_N$ 是结构物的一阶固有频率, ξ 为阻尼比。

通过假定不同波浪周期、结构一阶固有周期以及阻尼比的数值确定两个算例,其中每个算例中设定偏度为0.2、0.5和0.8,峰度为4、5和6,共组合形成9种工况。当S-N曲线材料参数 $K=1$,斜率参数 $m=3$ 、4、5和6时,以雨流计数法的疲劳损伤结果作为参考值,将所建立的神经网络模型与1.3节中三种宽带非高斯频域方法的结果进行对比。

3.1 算例1

算例1的双模态功率谱如图4所示,图中 T_w 取13 s, T_N 取3 s,阻尼比为0.03。当 $m=3\sim 6$ 时,在不同偏度和峰度组合条件下,神经网络模型与三种频域方法计算结果对比,如图5所示。由计算结果可知,相对于雨流计数法,非高斯WL方法的相对误差随 m 的增大而变大,当 $m=6$ 时最大误差为-15%;当 $m=3\sim 6$ 时非高斯DK方法的最大误差均在-10%以内,而非高斯TB方法最大误差在 $m=6$ 时已达到-20%。此外,以上三种频域方法计算结果的相对误差还随着峰度 γ_4 的增大而略微变大。相比之下,本文提出的神经网络模型更为准确,在 $m=3\sim 6$ 和不同偏度和峰度组合条件下的误差都未超过2%。


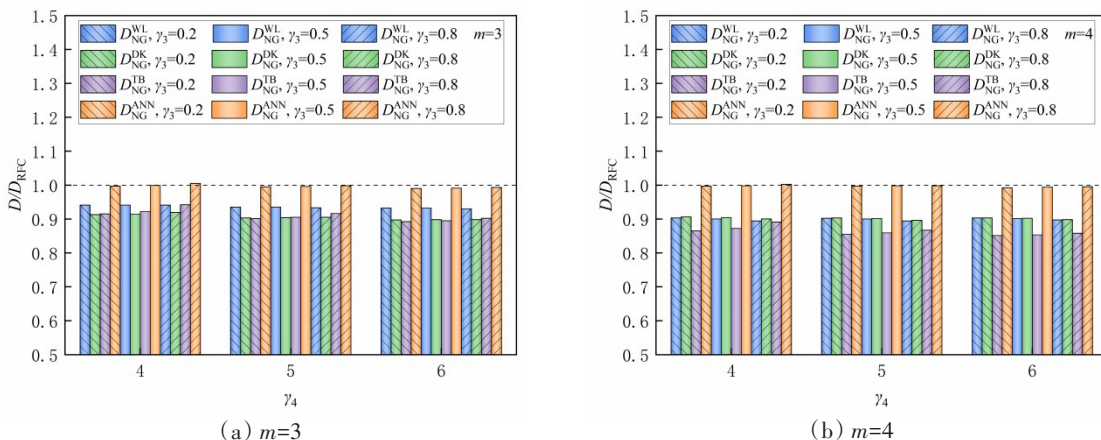


图4 双模态功率谱算例1

Fig.4 Bimodal power spectrum of Case 1



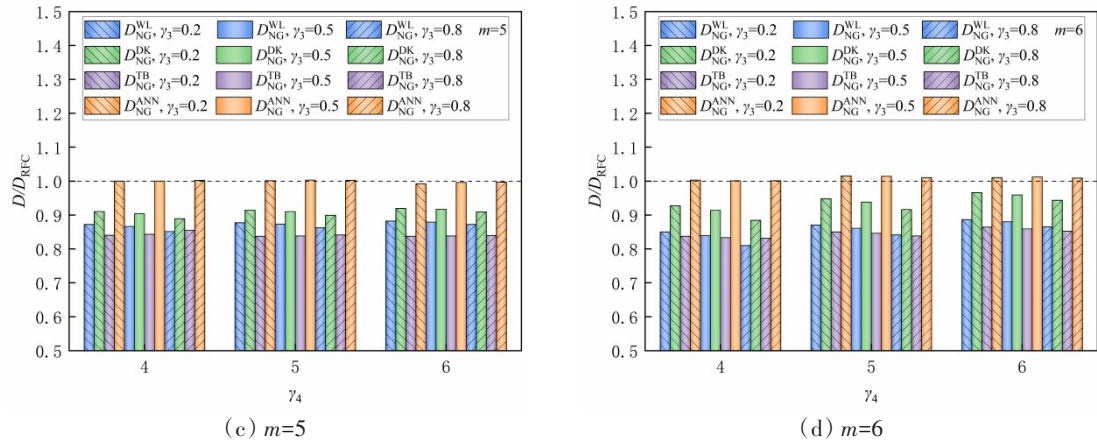


图5 算例1中ANN模型与不同频域方法评估疲劳损伤的对比
 Fig.5 Comparison of the fatigue damage evaluated by the ANN model and different spectral methods for Case 1

3.2 算例2

算例2的双模态功率谱如图6所示,其中 T_w 取12 s, T_N 取2 s,阻尼比为0.011。当 $m=3\sim 6$ 时,不同偏度和峰度组合条件下,神经网络模型与三种频域方法计算结果的对比如图7所示。与算例1结果趋势类似,相对于雨流计数法结果,非高斯WL方法计算的疲劳损伤随 m 的增大而变小,当 $m=6$ 时最大相对误差为-15%左右;当 $m=3\sim 6$ 时非高斯DK方法的最大误差均在-20%以内,非高斯TB方法最大误差在 $m=6$ 时已达到-25%;本文提出的神经网络模型具有更好的预报精度和鲁棒性,其最大误差未超过2%。


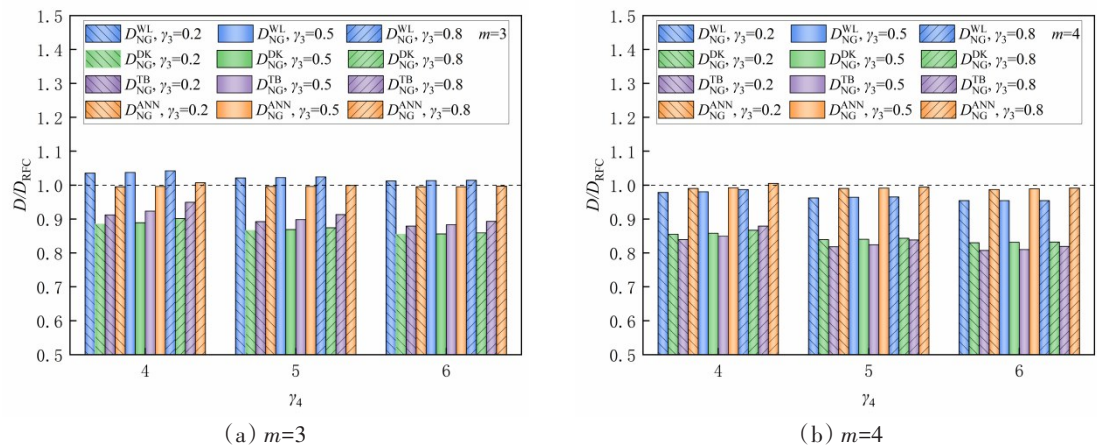


图6 双模态功率谱算例2
 Fig.6 Bimodal power spectrum of Case 2



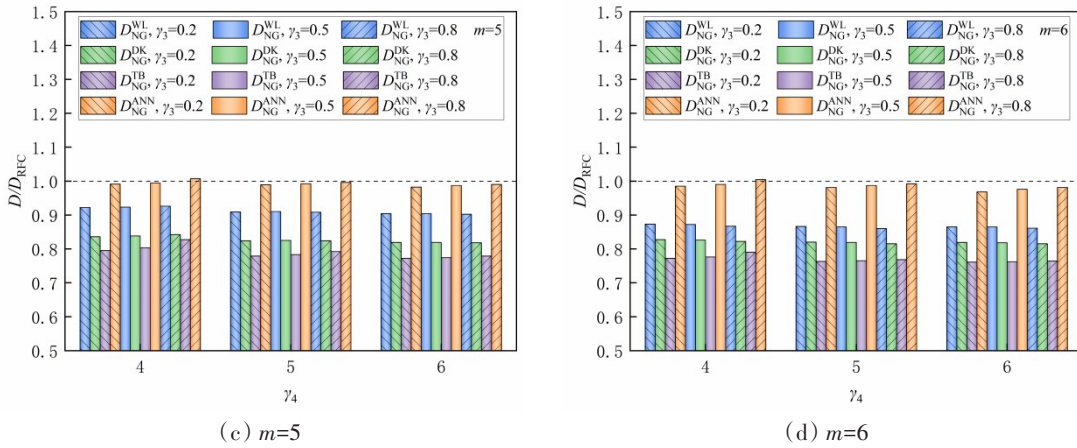


图7 算例2中ANN模型与不同频域方法评估疲劳损伤的对比

Fig.7 Comparison of the fatigue damage evaluated by the ANN model and different spectral methods for Case 2

4 结 论

本文基于非高斯TB方法和BP神经网络算法发展了一种宽带非高斯随机过程疲劳损伤评估方法,利用不同的功率谱进行数值试验,对该模型进行了训练和校验。通过数值模拟与分析,得到以下结论:

(1) 相比于雨流计数法,由非高斯WL法、非高斯DK法和非高斯TB法计算的疲劳损伤的相对误差随S-N曲线斜率参数和峰度的增大而变大,当 $m=6$ 时其最大相对误差分别达到-15%、-20%和-25%。

(2) 本文提出的基于神经网络算法的疲劳损伤预报模型能够准确、高效地评估宽带非高斯随机过程的疲劳损伤,与已有非高斯频域方法相比,具有更好的预报精度和鲁棒性,最大相对误差可控制在2%以内。

(3) 神经网络模型的输入层神经元、隐藏层神经元个数以及隐藏层层数对于模型预报结果的精度有着显著影响,因此需要确定最优的网络结构。

参 考 文 献:

[1] Bendat J S. Probability function for random response: Prediction of peaks, fatigue damage, and catastrophic failures[R]. NASA, 1964.

[2] Wirsching P H, Light M C. Fatigue under wide band random stresses[J]. Journal of the Structural Division, 1980, 106(7): 1593-1607.

[3] Dirlik T. Application of computers in fatigue analysis[D]. Coventry: University of Warwick, 1985.

[4] Benasciutti D, Tovo R. Spectral methods for lifetime prediction under wide-band stationary random processes[J]. International Journal of Fatigue, 2005, 27(8): 867-877.

[5] Li B, Rong K, Cai W, et al. Dynamic response of monopole-supported wind turbines considering non-Gaussian characteristics of wind inflow[J]. Applied Ocean Research, 2022, 127: 103321.

[6] Gao Z, Moan T. Fatigue damage induced by non-Gaussian bimodal wave loading in mooring lines[J]. Applied Ocean Research, 2007, 29: 45-54.

[7] Winterstein, S R. Nonlinear vibration models for extremes and fatigue[J]. Journal of Engineering Mechanics, 1988, 114(10): 1772-1790.

[8] Gao S, Zheng X Y, Wang B, et al. Assessment of fatigue damage induced by non-Gaussian bimodal processes with emphasis

- on spectral methods[J]. *Ocean Engineering*, 2021, 220: 108489.
- [9] Benasciutti D, Tovo R. Cycle distribution and fatigue damage assessment in broad-band non-Gaussian random processes[J]. *Probabilistic Engineering Mechanics*, 2005, 20(2): 115-127.
- [10] Ding J, Chen X. Fatigue damage evaluation of broad-band Gaussian and non-Gaussian wind load effects by a spectral method[J]. *Probabilistic Engineering Mechanics*, 2015, 41: 139-154.
- [11] Kim Y, Kim H, Ahn I G. A study on the fatigue damage model for Gaussian wideband process of two peaks by an artificial neural network[J]. *Ocean Engineering*, 2016, 111: 310-322.
- [12] Durodola J F, Li N, Ramachandra S, et al. A pattern recognition artificial neural network method for random fatigue loading life prediction[J]. *International Journal of Fatigue*, 2017, 99: 55-67.
- [13] Sun H, Qiu Y, Li J. A novel artificial neural network model for wide-band random fatigue life prediction[J]. *International Journal of Fatigue*, 2022, 157: 106701.
- [14] Petrucci G, Zuccarello B. Fatigue life prediction under wide band random loading[J]. *Fatigue & Fracture of Engineering Materials & Structures*, 2004, 27(12): 1183-1195.
- [15] Rychlik I. Note on cycle counts in irregular loads[J]. *Fatigue & Fracture of Engineering Materials & Structures*, 1993, 16(4): 377-390.
- [16] Winterstein S R, Kashef T. Moment-based load and response models with wind engineering applications[J]. *Journal of Solar Energy Engineering*, 2000, 122(3): 122-128.
- [17] Olagnon M, Guede Z. Rainflow fatigue analysis for loads with multimodal power spectral densities[J]. *Marine Structures*, 2008, 21(2-3): 160-176.