

# 改进生成对抗网络及其在结构非线性模型修正中的应用

王 俊<sup>1</sup>, 辛 宇<sup>1,2</sup>, 王佐才<sup>1,2,3</sup>, 戈 璧<sup>1</sup>

(1. 合肥工业大学土木与水利工程学院, 安徽 合肥 230009;  
2. 安徽省基础设施安全检测与监测工程实验室, 安徽 合肥 230009;  
3. 安全关键工业测控技术教育部工程研究中心, 安徽 合肥 230009)

**摘要:** 提出改进生成对抗网络(Generative Adversarial Network, GAN)并在结构非线性模型修正中成功应用。在改进的 GAN 中,通过引入代理模型的方式,增强网络判别器对非线性结构各节点响应关系特征的学习能力;为避免传统 GAN 存在的梯度消失问题,使用跳跃连接和密集连接等方式加强网络层之间的信息交流,并且通过引入组合目标函数,构建模型输入响应与输出参数之间的映射关系实现网络训练。在进行结构非线性模型修正时,结构的动力响应作为网络模型的输入,训练好的 GAN 模型能够根据输入数据的特征,输出非线性模型参数的最优值,从而实现结构非线性模型修正。通过对地震荷载作用下的 12 层钢筋混凝土框架结构进行数值模拟,验证了方法的可行性,并通过对比基于卷积神经网络的非线性模型修正结果,验证所提方法的优越性;最后进一步结合地震荷载作用下的悬臂铝梁振动台实验,验证了该非线性模型修正方法的可靠性。

**关键词:** 非线性模型修正;改进生成对抗网络;非线性结构;网络训练

**中图分类号:** TU311.3; O322 **文献标志码:** A **文章编号:** 1004-4523(2023)04-0934-12

**DOI:** 10.16385/j.cnki.issn.1004-4523.2023.04.006

## 引 言

当工程结构遭受到强荷载激励时,如地震、台风等,结构通常表现出较强的非线性行为,此时难以利用传统的线性理论对结构的状态进行评估<sup>[1-2]</sup>。提出一种适用于非线性结构的模型修正方法,实现对工程结构在强荷载激励作用下的动力响应预测,为工程人员提供精确的非线性模型并进行力学行为分析和预测,具有重要的理论意义和工程应用价值<sup>[3-4]</sup>。

结构非线性模型修正在近些年来得到了国内外学者的广泛关注,并且有关于非线性模型修正的理论和方法取得了一系列的进展。例如, Song 等<sup>[5]</sup>将标准化的非线性模态参数作为贝叶斯非线性模型修正方法的输入,并利用马尔可夫链蒙特卡罗随机抽样方法获得模型参数的最大后验概率分布,初步探讨了模型误差对非线性有限元模型修正结果的影响。Wang 等<sup>[6]</sup>提出了基于结构非平稳振动响应主分量瞬时特征参数的非线性模型修正方法,该方法

利用非平稳振动响应主分量的瞬时特征参数中隐含的结构非线性振动信息对结构的非线性模型进行修正。Lin 等<sup>[7]</sup>利用结构在地震荷载作用下的动力响应数据表征结构的非线性行为,然后,进一步构建基于实测结构与非线性模型之间的关于动力响应残差的目标函数,并利用优化算法来最小化误差函数,从而获得结构非线性模型的最优参数。

随着数据科学和机器学习算法的飞速发展,基于数据驱动的系统参数识别及模型修正技术得到了广泛应用<sup>[8-9]</sup>。基于深度学习算法的非线性模型修正流程一般可表述为:(1)提取初始模型在不同非线性参数组合下的响应数据作为网络模型的训练数据;(2)利用深度学习算法,从训练数据中学习数据特征与非线性参数之间的复杂映射关系,实现网络模型的训练;(3)将非线性结构的实测响应数据作为真实值输入到训练后的网络模型中,利用网络的泛化特性对结构模型的非线性参数进行识别,从而实现结构非线性模型修正。

本文结合深度学习算法在数据特征学习方面的优势,提出了一种基于改进生成对抗网络(Genera-

**收稿日期:** 2021-11-19; **修订日期:** 2022-02-11

**基金项目:** 国家自然科学基金优秀青年科学基金资助项目(51922036);安徽省重点研发计划资助项目(1804a0802204);中央高校基本科研业务费专项资金资助项目(JZ2020HGPP0117)。

tive Adversarial Network, GAN)的结构非线性模型修正方法。该方法利用改进GAN强大的拟合能力去学习结构非线性动力响应与待修正参数之间的映射关系,训练好的GAN能够根据输入响应数据的特征,输出非线性模型参数的最优值,从而实现结构非线性模型修正,将非线性模型修正归结为求解参数的正问题。为了验证方法的可行性,本研究对地震荷载作用下的12层钢筋混凝土框架结构模型进行修正,并讨论了跳跃连接、密集连接以及组合目标函数等对网络模型训练过程的影响;此外,进一步讨论了不同噪声水平、不同数量采样点对非线性模型修正结果的影响;最后,利用一根具有非线性边界条件的悬臂铝梁振动台试验进一步验证了该方法的可靠性。

## 1 理论背景

### 1.1 GAN原理

GAN是由Goodfellow等<sup>[10]</sup>提出的一种无监督学习算法框架,主要由一个生成器(Generator, G)和一个判别器(Discriminator, D)组成。在训练GAN的过程中,生成器的输入数据是一组随机变量 $z$ ,生成器旨在将生成样本数据 $G(z)$ 的分布逼近真实样本数据分布来欺骗判别器;判别器的输入为真实数据 $x$ 和生成样本数据 $G(z)$ ,输出为一个概率值,若概率值为1,则可认为判别器的输入为真实样本,若为0,则代表输入来自生成样本。因此,判别器的最终目的是要准确识别出输入数据是否来自真实样本<sup>[10]</sup>。

在训练过程中,生成器学习真实样本分布,并能根据网络输入随机生成伪样本数据欺骗判别器,而判别器的功能旨在准确区分真实样本和伪样本<sup>[11]</sup>。GAN在训练过程中,通过生成器和判别器的网络参数优化,从而实现对实测样本的数据特征学习,网络参数的优化目标函数如下式所示:

$$\arg \min_G \max_D V(D, G) = E_{x \sim p_{data}(x)} [\lg D(x)] + E_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (1)$$

式中  $E$ 代表数学期望; $D(x)$ 为判别器能正确识别出真实样本的概率; $D(G(z))$ 为判别器将生成样本识别成真实样本的概率。传统GAN结构如图1所示<sup>[10]</sup>。

当利用传统GAN对非线性模型参数进行识别时,主要存在的问题是:(1)在GAN训练中,生成器负责构建网络模型输入响应与输出参数之间的映射关系,判别器负责学习样本中非线性参数的分布,并

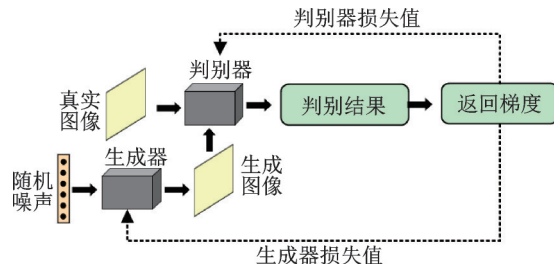


图1 传统GAN架构图

Fig. 1 The architecture diagram of traditional GAN

对生成器生成的假样本 $G(z)$ 进行判别。然而,由于判别器的输入数据只有生成参数数据和真实参数数据,这就导致训练样本中的结构响应数据没有参与到判别器的训练过程,进而造成整个GAN模型训练过程中判别器不能给生成器的修正方向做出准确的指示。例如,在GAN训练过程中,存在两组训练数据 $(Y_a, P_a)$ 和 $(Y_b, P_b)$ ,判别器仅对参数 $P_a$ 和 $P_b$ 的分布进行学习,并不会去构建响应 $Y_a$ 与参数 $P_a$ 、响应 $Y_b$ 与参数 $P_b$ 之间的关系,从而导致当输入为响应 $Y_a$ 、输出为参数 $P_b$ 时,判别器会认为生成器生成的参数 $P_b$ 是符合真实样本数据分布的,当训练数据量越大时,这种现象就会越明显。因此,如何利用GAN的判别器学习结构响应与模型待修正参数之间的映射关系是实现非线性模型修正的关键步骤。(2)对于复杂的非线性结构,其模型中通常包括大量的非线性参数,此时,不能仅依靠判别器给出的概率值去检验生成样本是否符合真实分布。主要原因是由于判别器仅能区分出每组非线性参数的真伪,不能对单个非线性参数的真实分布进行检验。

此外,对于传统的GAN,其在整个训练过程中仅依靠判别器提供的损失梯度实现对生成器和判别器的参数优化。这种方式容易在训练初期出现梯度消失问题,导致训练失败或者降低了生成样本的质量。因此,基于上述难题,本文提出基于改进GAN的结构非线性模型修正方法。

### 1.2 改进的GAN模型

在改进GAN中,通过引入代理模型的方式增强了网络模型中判别器对非线性结构各节点响应关系特征的学习能力。该方法利用CNN模型作为代理模型,其主要优点为:增加的CNN代理模型能够根据生成器生成的参数样本 $G(z)$ 计算出验证节点的响应 $C(G(z))$ ,从而可以建立起输入节点响应与输出参数之间的对应关系。改进GAN中的判别器采用的是一种全卷积网络(Fully Convolutional Networks, FCN),其输入数据为多通道的节点响应数据,每个通道与结构的节点相对应,因此,网络训练过程具备更多的物理学意义,即多通道数据之间的

关系与实际结构节点之间的振动特性,如模态振型、自然频率等相匹配,使生成器产生的结果更加符合真实情况。另外,在网络训练过程中,根据组合目标函数提供的损失梯度对网络生成器和判别器的参数进行优化,可以给生成器提供更多的损失梯度以加强数据特征的学习,避免了在网络训练初期因判别器太强而导致生成器损失值接近于0,失去修正方向。值得注意的是,CNN作为在准备阶段已经训练好的代理模型,其参数在整个GAN训练过程中都是固定不变的。

本文所采用的生成器是一种密集连接的卷积网络(Densely Connected Convolutional Networks,

DenseNets)<sup>[12]</sup>,其架构图如图2所示。DenseNets内部包含三个连续的密集块,密集块构造图如图3所示。在结构非线性模型修正中,生成器的输入为结构的动力响应,输出为模型的待修正参数。在网络训练过程中,DenseNets使用的是密集连接和跳跃连接,而不是传统的连续网络层,这样可以提高网络层之间的信息流。密集连接和跳跃连接的使用可以提高网络模型的训练效率和特征提取能力,并且加强了数据传递的准确性,在很大程度上减少了整个网络模型训练权值参数的数量,梯度消失问题也可以得到改善<sup>[11]</sup>。在这种情况下,网络模型所需要的训练数据量也可以减少,从而增强了网络的训练效率。

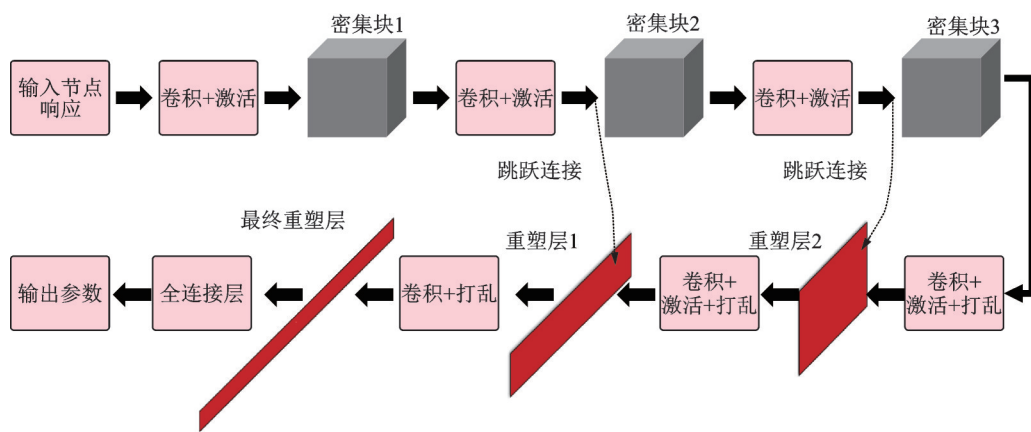


图2 生成器构造图

Fig. 2 The diagram of generator construction




图3 密集块构造图

Fig. 3 The diagram of dense block construction

### 1.3 利用生成对抗网络进行模型修正的原理

对于非线性结构,结构的动力响应 $y$ 与设计参数组 $\mathbf{p}=(p_1, p_2, p_3, \dots, p_k)$ 之间的关系可以表示为:

$$y=f(\mathbf{p}=(p_1, p_2, p_3, \dots, p_k)) \quad (2)$$

设计参数组 $\mathbf{p}$ 为结构自身固有特性,即为自变量,结构在外部荷载作用下产生的动力响应 $y$ 为因变量,动力响应可以通过测量得到,而设计参数组 $\mathbf{p}$ 通常是未知的,因此,非线性模型的初始参数组与设计参数组 $\mathbf{p}$ 之间通常存在偏差,这种偏差会导致结构动力响应的模拟结果与实际结构响应之间存在误差,将式(2)进一步改写为:

$$\mathbf{p}=(p_1, p_2, p_3, \dots, p_k)=f^{-1}(y) \quad (3)$$

式中 $f^{-1}$ 代表结构响应 $y$ 与设计参数 $\mathbf{p}$ 之间的函数关系,利用生成对抗网络强大的拟合能力去逼近二者之间的非线性映射关系 $f^{-1}$ ,训练好的网络模型即为 $f^{-1}$ ,然后就可以根据结构实测动力响应去直接计算结构的设计参数组 $\mathbf{p}$ ,把模型修正的逆问题归结为求解参数组 $\mathbf{p}$ 的正问题,生成对抗网络进行模型修正的具体流程如图4所示。

### 1.4 基于改进的GAN进行结构非线性模型修正

改进GAN的训练过程如图5所示,其主要过程可分为两个部分:(1)数据准备及卷积神经网络训练;(2)GAN的训练及样本生成。



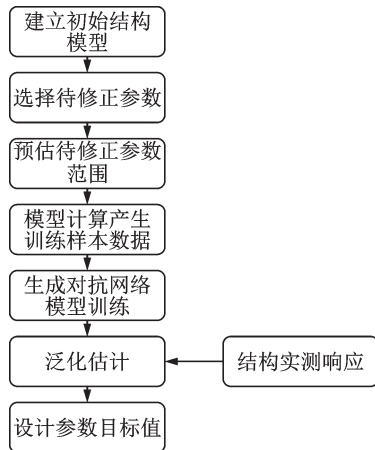


图 4 基于 GAN 的模型修正流程图

Fig. 4 The model updating procedure based on GAN

在数据准备及卷积神经网络的训练阶段,首先

处理实测各节点响应数据  $Y_R=[Y_1, Y_2, Y_3, Y_4]$ , 将实测各节点响应数据分为输入响应数据  $Y_S$  和验证响应数据  $Y_P$  两个部分, 选取结构非线性模型中的测点  $Y_P=[Y_4]$  作为验证节点响应, 其他测点  $Y_S=[Y_1, Y_2, Y_3]$  作为输入节点响应。将非线性参数  $Z_R=[Z_1, Z_2, Z_3, Z_4]$  作为 CNN 的输入数据,  $Y_P=[Y_4]$  作为 CNN 的输出, 通过训练 CNN, 构建非线性模型参数  $Z_R$  与  $Y_P$  之间的映射关系。将训练后的 CNN 以代理模型的方式嵌入到 GAN 中。然后, 将  $Y_S$  作为生成器的输入, 通过生成器输出结构非线性模型的待修正参数  $G(Y_S)$ , 其中,  $G(Y_S)$  又作为代理模型的输入, 最终获得非线性模型在生成器输出参数组合条件下的验证节点响应数据  $C(G(Y_S))$ 。

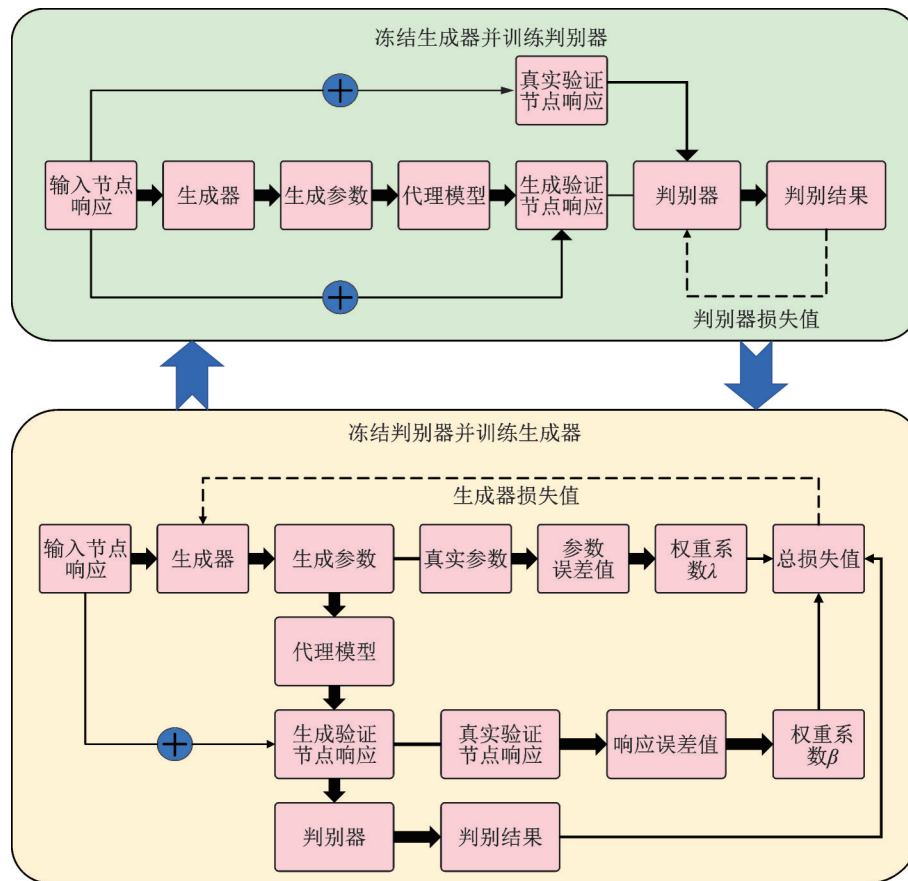


图 5 改进的 GAN 对抗训练过程

Fig. 5 The adversarial training procedure of the improved GAN

将代理模型预测的验证节点响应数据  $C(G(Y_S))$  与  $Y_S$  结合, 得到多通道条件下的生成响应数据  $Y_G=[Y_1, Y_2, Y_3, C(G(Y_S))]$ 。将  $Y_G$  与  $Y_R$  相混合, 把混合后的数据组合作为判别器的输入, 判别器的输出层通过 Sigmoid 函数来执行回归操作, 最后通过计算交叉熵损失来区分  $Y_R$  与  $Y_G$ 。计算出损失值后将损失梯度返回到判别器的每一层, 从而完成对判别器的训练。其中, Sigmoid 函数如下式所示:

$$\text{Sigmoid}(x) = \frac{e^x}{e^x + 1} \quad (4)$$

当判别器训练完成后, 其参数固定, 此时开始训练生成器,  $Y_S$  再次作为生成器的输入数据, 得到待识别参数  $G(Y_S)$ ; 然后, 将  $G(Y_S)$  代入到代理模型中生成验证节点响应  $C(G(Y_S))$ ; 进一步将获得的  $C(G(Y_S))$  与  $Y_S$  融合, 生成响应数据  $Y_G=[Y_1, Y_2, Y_3, C(G(Y_S))]$ , 将  $Y_G$  输入到判别器中, 用以计算

交叉熵损失  $L_{GAN}$ , 如下式所示:

$$L_{GAN} = \arg \min_G \max_D E_{a,b} [\ln D(a,b)] + E_a [\ln(1 - D(a, C(G(a))))] \quad (5)$$

式中  $a$  代表训练节点响应数据;  $b$  代表实测的验证节点响应;  $C(G(a))$  代表代理模型根据生成器生成参数预测的验证节点响应。

为了改进 GAN 在训练时容易出现梯度消失的缺点, 以及增强低频数据结构特征的学习能力, 在生成器的训练过程中, 根据参数和响应的关系额外设置 2 个损失函数。根据相关文献表明<sup>[12]</sup>, 能够评估数据之间距离的 MSE 损失函数具有很强的学习低频数据特征的能力。本研究分别在生成的参数样本  $G(Y_s)$  与真实参数样本  $\theta_R$ , 以及生成的验证节点响应  $C(G(Y_s))$  与实测验证节点响应  $Y_p$  之间构造 2 个 MSE 损失函数  $L_{\varepsilon-dis}$  和  $L_{y-dis}$ 。此时, 生成器的学习目标为生成可以欺骗判别器的参数, 缩小与每个真实参数之间的误差绝对值, 并且保证代理模型根据生成参数  $G(Y_s)$  而预测的验证节点数据  $C(G(Y_s))$  与实测验证节点数据  $Y_p$  之间的误差绝对值足够小。生成器的目标函数可表示为:

$$L_G = L_{GAN} + \lambda L_{\varepsilon-dis} + \beta L_{y-dis} \quad (6)$$

式中  $\lambda$  和  $\beta$  分别是损失函数  $L_{\varepsilon-dis}$  与  $L_{y-dis}$  的权重系数, 设置权重的原因是由于  $L_{GAN}$  在量级上比  $L_{\varepsilon-dis}$  和  $L_{y-dis}$  大得多, 必须通过权重系数来平衡三个损失函数对网络训练的影响,  $\lambda$  与  $\beta$  的建议取值为 1000<sup>[13]</sup>。

采用归一化均方差 N-MSE 计算  $L_{\varepsilon-dis}$  与  $L_{y-dis}$  损失<sup>[12]</sup>, 其中, N-MSE 表示如下:

$$Loss_{N-MSE} = \sum_{k=1}^n \frac{(Y_k - \hat{Y}_k)^2}{Y_k^2} \quad (7)$$

式中  $n$  为训练样本采样点的总个数;  $Y_k$  代表实测数据;  $\hat{Y}_k$  代表预测数据。

## 2 数值模拟

### 2.1 结构非线性模型的建立和振动响应分析

为了验证基于改进的 GAN 的结构非线性模型修正方法的有效性和可靠性, 本节对地震荷载作用下的 12 层缩尺钢筋混凝土框架结构进行数值模拟, 该数值模型根据同济大学土木工程防灾国家重点实验室的 12 层钢筋混凝土标准框架振动台模型的结构特点建立<sup>[14]</sup>, 建立的非线性模型如图 6(a) 所示。

该框架结构为  $\frac{1}{10}$  的缩尺模型, 层高为 0.3 m, 结构总高度为 3.6 m, 每层楼板尺寸为 0.6 m × 0.6 m。

利用 OpenSees 软件建立该框架结构的非线性

模型, 模型在地震激励作用下的非线性动力行为主要是通过定义梁柱单元的材料非线性来实现的。其中, 框架结构的混凝土材料采用 Concrete 02 单轴材料进行定义, 钢筋采用 Steel 02 材料进行模拟, 两类材料的本构模型分别如图 6(b) 所示。通过设置不同的材料参数实现对框架结构在地震荷载作用下的非线性特征模拟。其中, 混凝土材料的滞回特性主要通过如下参数定义: 混凝土抗压强度  $f_c$ 、屈服残余强度  $f_u$ 、峰值应变  $\varepsilon_{max}$ 、残余应变  $\varepsilon_u$  以及抗拉强度  $f_t$ ; 类似地, 钢筋材料的非线性特征可以通过屈服强度  $f_y$ 、初始弹性模量  $E_s$  和屈服比  $b$  三个非线性参数进行定义。为了模拟结构非线性, 在模型建立过程中, 梁柱单元的混凝土材料采用相同的非线性参数定义, 钢筋材料采用两种材料分别定义, 因此, 框架模型中共包括 11 个非线性材料参数, 其中 5 个混凝土材料参数: 混凝土抗压强度  $f_c$ 、屈服残余强度  $f_u$ 、峰值应变  $\varepsilon_{max}$ 、残余应变  $\varepsilon_u$  以及抗拉强度  $f_t$ ; 3 个柱所用钢筋材料参数: 屈服强度  $f_y^{Col}$ , 初始弹性模量  $E_s^{Col}$ , 屈服比

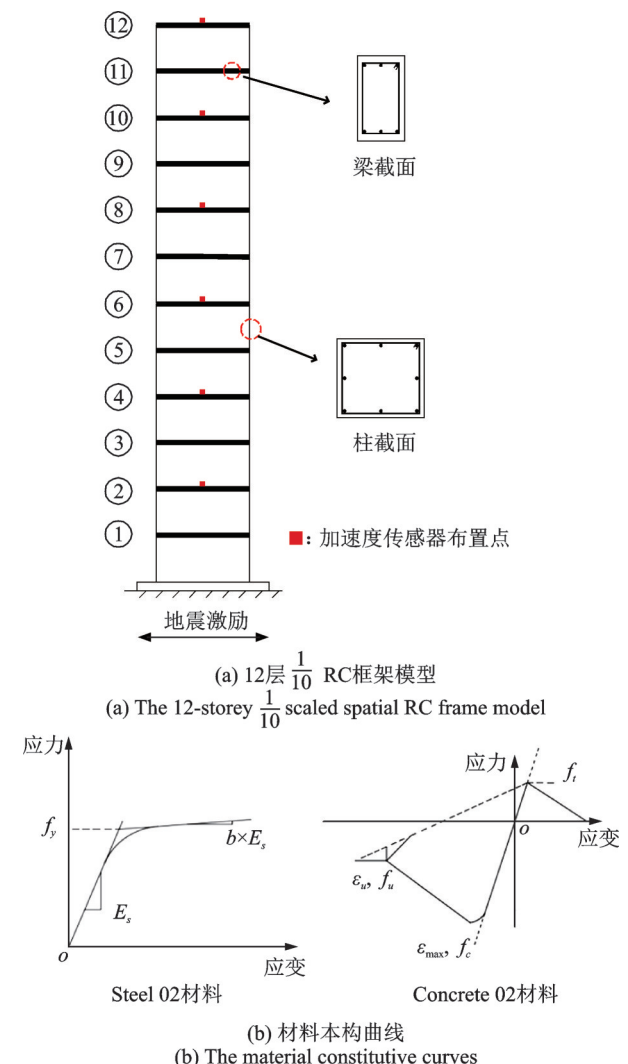


图 6 基于 OpenSees 的非线性模型建立

Fig. 6 The developed nonlinear model based on OpenSees

$b^{\text{Col}}$ ,上标“Col”表示柱;3个梁所用钢筋材料参数:屈服强度 $f_y^{\text{B}}$ ,初始弹性模量 $E_s^{\text{B}}$ ,屈服比 $b^{\text{B}}$ ,上标“B”表示梁。结构的初始非线性参数设置如表1所示。

表1 非线性模型的初始参数

Tab. 1 The initial parameters of the nonlinear model

混凝土材料参数		钢筋材料参数	
$f_c/\text{Pa}$	$6.20 \times 10^6$	$f_y^{\text{Col}}/\text{Pa}$	$3.91 \times 10^8$
$f_u/\text{Pa}$	$1.30 \times 10^6$	$E_s^{\text{Col}}/\text{Pa}$	$2.00 \times 10^{11}$
$\epsilon_{\text{max}}$	$2.00 \times 10^{-3}$	$b^{\text{Col}}$	0.05
$\epsilon_u$	$3.30 \times 10^{-3}$	$f_y^{\text{B}}/\text{Pa}$	$3.47 \times 10^8$
$f_t/\text{Pa}$	$8.68 \times 10^5$	$E_s^{\text{B}}/\text{Pa}$	$2.00 \times 10^{11}$
		$b^{\text{B}}$	0.10

在对该框架结构进行动力响应计算时,选择的外部激励为1940年的El Centro地震波,主要强震部分持续时间为26 s左右,全部波形长为54 s,采样频率为50 Hz。利用Newmark- $\beta$ 积分算法对框架结构在地震荷载激励作用下的非线性动力响应进行计算。同时,将框架结构各层的加速度响应作为结构的已知响应,并在获得的加速度响应中加入5%的随机高斯白噪声模拟结构的实测动力响应。地震荷载作用下,框架结构顶层的加速度响应如图7所示。底层框架柱在地震激励作用下的弯矩-曲率滞回曲线如图8所示。




图7 顶层加速度响应

Fig. 7 The acceleration response of the top floor




图8 底层柱的弯矩-曲率滞回曲线

Fig. 8 The moment-curvature hysteretic curve of the bottom column

## 2.2 构建改进的GAN模型

基于改进的GAN进行结构非线性模型修正,首先应对GAN进行训练,总样本数据的获取如下所述:(1)以框架结构模型的初始值为真实值,采用拉丁超立方抽样方法<sup>[15]</sup>在真实值上下20%的参数区间内生成100组随机参数样本;(2)将100组参数代入到非线性模型中,获得结构在地震荷载作用下的动力响应数据,并将动力响应数据分为输入响应数据和验证响应数据2个部分;(3)以待修正模型参数作为输入,验证响应数据作为代理模型的输出,构建用以训练代理模型的样本数据集;(4)以输入响应数据作为网络模型训练数据的输入,待修正非线性参数组合作为网络的输出,构建用以训练改进GAN的样本数据集。为了保证网络训练时的稳定性,本研究分别选取框架结构第2,4,6,8,10,12层的加速度响应数据作为网络的样本响应数据,即一个完整样本的响应数据为 $Y_R=[Y_2, Y_4, Y_6, Y_8, Y_{10}, Y_{12}]$ ,并将完整样本的响应数据处理为输入响应数据 $Y_S=[Y_2, Y_4, Y_6, Y_8, Y_{10}]$ 以及验证响应数据 $Y_P=[Y_{12}]$ 。

将总样本数据按3:1的比例分为训练样本和测试样本,即75组数据用于网络训练,25组用于网络测试。每一组完整样本数据中包括6个楼层的加速度响应和11个非线性参数。将完整训练样本数据中6个楼层的加速度响应 $Y_R=[Y_2, Y_4, Y_6, Y_8, Y_{10}, Y_{12}]$ 处理为输入响应数据 $Y_S=[Y_2, Y_4, Y_6, Y_8, Y_{10}]$ 以及验证响应数据 $Y_P=[Y_{12}]$ 这2个部分,11个材料参数 $\theta_R=[\theta_1, \theta_2, \theta_3, \theta_4, \theta_5, \theta_6, \theta_7, \theta_8, \theta_9, \theta_{10}, \theta_{11}]$ 作为待识别材料参数。改进GAN中的代理模型需要根据非线性参数预测验证节点的加速度响应数据,因此,在GAN训练之前,首先对基于CNN的网络模型进行训练,并确保代理模型能够根据输入的非线性参数预测出验证响应数据。

将训练后的代理模型嵌入到GAN模型中,然后将前5个楼层的加速度数据 $Y_S$ 作为GAN的生成器输入,待修正参数作为输出,对GAN进行训练,具体训练流程如图5所示。

在改进的GAN训练中,一次训练所抓取的样本数据量取75,总训练轮次取300,学习率取 $1 \times 10^{-4}$ 。同时,为了防止在训练过程中出现过拟合问题,在改进的GAN中,采用Dropout技术在每层训练过程中随机抽取一部分神经元节点丢弃,确保网络的泛化能力得到增强。在本文所采用Dropout方法中,每个神经元丢弃的概率值均取0.5,最大程度地增强了GAN的泛化能力<sup>[12]</sup>。



### 2.3 非线性模型参数识别的精度评价指标

将识别出的非线性模型参数代入非线性模型中计算结构动力响应,通过对比识别响应与真实响应来衡量非线性模型参数识别精度,为了量化非线性模型修正结果的精确性,本文定义的误差函数如下式所示<sup>[11]</sup>:

$$\epsilon = \frac{\|y_r - G(a)\|_2^2}{\|y_r\|_2^2} = \frac{\sqrt{\sum_{i=1}^n (y_i - G(a)_i)^2}}{\sqrt{\sum_{i=1}^n y_i^2}} \times 100\% \quad (8)$$

式中  $y_r$  为真实样本数据; $G(a)$  为识别参数数据。 $\epsilon$  越小,代表生成样本和真实样本拟合得越接近。

### 2.4 结构非线性模型修正

改进 GAN 训练 300 个轮次后,其测试集损失值如图 9 所示。为了凸显本文所提方法在训练过程中的优越性,将改进 GAN 训练过程与另外一种 GAN 的训练过程进行对比,图 9 也给出了用作对比的 GAN 训练过程中测试集损失值,用作对比的 GAN 仅在改进 GAN 架构的基础上去除了生成器内部的跳跃连接,并且不再组建额外的损失函数,即其生成器仅仅依靠判别器计算的损失值进行更新迭代。

由图 9 的损失曲线可以看出,用作对比的 GAN 在训练初期测试集损失值增大,经过多轮次训练后才呈现下降趋势,其损失值下降趋势并不稳定,在训练 150 个轮次后逐渐平稳,在第 261 个轮次时其损失值达到最小,为 0.11。改进 GAN 测试集损失值在训练初期急剧下降,然后趋于平稳,在第 50 个训练轮次后,其损失值趋向收敛,在第 266 个轮次时出现最小损失值 0.07。由训练结果可知,改进 GAN 无论是在收敛速度、平稳性以及精确度上都优于用作对比的 GAN,这是由于在改进 GAN 中采用了跳跃连接和密集连接,可以加强浅层网络层




图 9 改进 GAN 和对比 GAN 训练过程

Fig. 9 Training process of the improved GAN and the compared GAN

和深层网络层之间的信息交流,并且组合目标函数在网络训练初期给模型训练提供额外的损失值,可以避免 GAN 在训练过程中存在的梯度消失问题。

当 GAN 的训练完成之后,便可以以结构的实测动力响应数据为输入,对非线性模型的待修正参数进行识别。基于建议的非线性模型修正方法,修正后的非线性参数如表 2 和 3 所示。由表 2 和 3 可知,基于本文提出的方法,能够较精确地实现地震荷载作用下的结构非线性模型修正。其中,混凝土材料参数的最大修正误差为 2.61%,钢筋材料参数的最大修正误差仅为 3.75%,所有非线性参数的修正结果均小于 4%。将修正后的非线性参数代入到初始的框架模型中,得到结构在地震荷载作用下的加速度响应,误差指标分别为: $E_{acc}^{(12)}=1.45\%$ , $E_{acc}^{(10)}=1.35\%$ , $E_{disp}^{(12)}=2.4\%$ , $E_{acc}^{(12)}$  代表顶层节点加速度识别响应与真实响应的误差, $E_{acc}^{(10)}$  代表第 10 层节点加速度识别响应与真实响应的误差, $E_{disp}^{(12)}$  代表顶层节点位移识别响应与结构真实响应之间的误差。修正后的结构响应与结构真实响应的对比结果如图 10 所示。由图 10 可以看出,修正后的非线性模型能够准确地预测结构的动力响应。因此,基于改进的 GAN 模型,能够有效地实现结构非线性模型修正。

表 2 5% 高斯白噪声工况下的混凝土材料参数修正结果

Tab. 2 The updated results of the concrete material parameters under 5% Gaussian white noise

参数	真实值	识别值	误差/%
$f_c/\text{Pa}$	$6.2 \times 10^6$	$6.36 \times 10^6$	2.61
$f_u/\text{Pa}$	$1.3 \times 10^6$	$1.32 \times 10^6$	1.22
$\epsilon_{max}$	$2 \times 10^{-3}$	$1.98 \times 10^{-3}$	-1.05
$\epsilon_u$	$3.3 \times 10^{-3}$	$3.35 \times 10^{-3}$	1.54
$f_t/\text{Pa}$	$8.68 \times 10^5$	$8.52 \times 10^5$	-1.83

表 3 5% 高斯白噪声工况下的钢筋材料参数修正结果

Tab. 3 The updated results of the reinforcement material parameters under 5% Gaussian white noise

参数	真实值	识别值	误差/%
$f_y^{\text{Col}}/\text{Pa}$	$3.91 \times 10^8$	$3.85 \times 10^8$	-1.64
$E_s^{\text{Col}}/\text{Pa}$	$2 \times 10^{11}$	$1.97 \times 10^{11}$	-1.43
$b^{\text{Col}}$	0.05	0.0496	-0.71
$f_y^{\text{B}}/\text{Pa}$	$3.47 \times 10^8$	$3.34 \times 10^8$	-3.75
$E_s^{\text{B}}/\text{Pa}$	$2 \times 10^{11}$	$2.04 \times 10^{11}$	1.74
$b^{\text{B}}$	0.1	0.099	-0.56

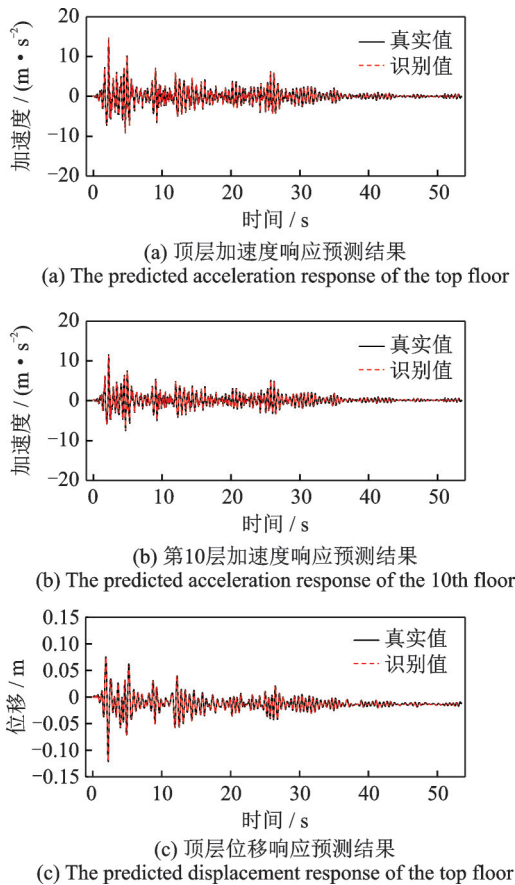


图10 基于修正后非线性模型的预测结果

Fig. 10 The predicted results based on updated nonlinear model

### 3 结构非线性模型修正的影响因素分析

#### 3.1 不同噪声水平对非线性模型修正的影响

为研究不同噪声下所提出的结构非线性模型修正方法的有效性,本节分别对5%、10%和20%噪声影响下,结构非线性模型修正结果的可靠性进行研究。利用2.2节中训练后的GAN,对不同噪声工况下的非线性模型进行修正,修正的结果分别如表4和5所示。

由修正结果可知,在5%噪声工况下,非线性参数的最大识别误差为2.99%;在10%噪声工况下,

表4 不同噪声水平下混凝土材料参数的修正误差

Tab. 4 The updated errors of the concrete material parameters under different noise levels

测试工况	修正误差/%				
	$f_c$	$f_u$	$\epsilon_{\max}$	$\epsilon_u$	$f_t$
5% 噪声	2.61	1.22	-1.05	1.54	-1.83
10% 噪声	-1.90	-1.96	0.18	-1.05	-1.02
20% 噪声	2.76	-0.15	0.25	-0.81	-1.51

表5 不同噪声水平下钢筋材料参数的修正误差

Tab. 5 The updated errors of the reinforcement material parameters under different noise levels

测试工况	修正误差/%					
	$f_y^{Col}$	$E_s^{Col}$	$b^{Col}$	$f_y^B$	$E_s^B$	$b^B$
5% 噪声	-1.64	-1.43	-0.71	-2.99	1.74	-0.56
10% 噪声	-1.82	-1.42	-0.89	-3.61	1.88	0.59
20% 噪声	-2.60	-1.44	-1.04	-3.85	-3.67	0.81

最大识别误差为3.61%;在20%噪声工况下,最大识别误差为3.85%。不同噪声工况下结构顶层加速度响应预测值与实测响应之间的误差值 $E_{acc}^{(12)}$ :在5%噪声工况下, $E_{acc}^{(12)}=1.45%$ ;在10%噪声工况下, $E_{acc}^{(12)}=1.93%$ ;在20%噪声工况下, $E_{acc}^{(12)}=8.22%$ 。基于上述的修正结果可知,随着噪声水平的增加,参数的识别精度略有降低,但最大相对误差仍控制在4%以内。通过上述计算结果可知,本文所提出的非线性模型修正方法能够精确地实现非线性框架结构的模型修正,且具有较好的噪声鲁棒性。

#### 3.2 不同采样点数量对非线性模型修正的影响

在进行改进GAN训练时,所采用的输入数据为地震荷载作用下结构响应加速度的时间序列。在地震荷载作用下,结构的加速度响应序列的总采样点数为2756,在2.4节中,为了利用改进的GAN对框架结构模型的非线性参数进行修正,所采用的输入样本点数为512。一般情况下,使用的样本点数量越多,输入信息中所包含的结构非线性信息越充分,但样本点数据过多,会显著影响计算效率。因此,为研究本文所提出的方法在不同数量样本点训练下的识别精度以及训练时间,本节分别采用256个样本点、128个样本点用以训练网络模型。

在三个不同采样点工况下,网络模型的预测结果分别如表6和7所示。各工况所花费训练时间如图11所示。由计算结果可知,当样本点数量为128时,参数的最大识别误差为5.34%, $E_{acc}^{(12)}=2.57%$ ;样本点数量为256时,最大识别误差为4.96%, $E_{acc}^{(12)}=2.12%$ ;样本点数量为512时,最大识别误差仅为3.99%, $E_{acc}^{(12)}=1.45%$ ;当增大训练样本采样点个数时,其识别参数中最大相对误差和顶层加速度响应识别误差都有一定程度的减小。采样点越多,节点响应分布高频部分描述得越清楚,能加强网络模型对响应高频分布的学习,但更多的采样点个数会显著增加计算成本。因此,基于该工况的模型修正结果可知,选择合适的采样点数量可以较好地拟合响应的主要分布,网络模型也能有效地学习到结构响应中所隐含的非线性信息,可以准确地实现结



构非线性模型修正,同时缩短网络模型的训练时间,提高计算效率。

表 6 不同采样点工况下混凝土材料参数的修正误差

Tab. 6 The updated errors of the concrete material parameters under different sampling points

工况	修正误差/%				
	$f_c$	$f_u$	$\epsilon_{\max}$	$\epsilon_u$	$f_t$
128 样本点	0.17	-1.44	-2.19	-0.03	0.51
256 样本点	0.86	-1.09	-2.46	-0.57	-1.23
512 样本点	2.61	1.22	-1.05	1.54	-1.83

表 7 不同采样点工况下钢筋材料参数的修正误差

Tab. 7 The updated errors of the reinforcement material parameters under different sampling points

工况	修正误差/%					
	$f_y^{\text{Col}}$	$E_s^{\text{Col}}$	$b^{\text{Col}}$	$f_y^{\text{B}}$	$E_s^{\text{B}}$	$b^{\text{B}}$
128 样本点	-1.98	-1.86	0.01	-5.34	1.83	-3.01
256 样本点	-2.07	-2.51	-1.09	-4.96	1.76	-2.22
512 样本点	-1.64	-1.43	-0.71	-3.99	1.74	-0.56




图 11 不同采样点工况下的网络训练时间

Fig. 11 The training time of the networks under different sampling points

#### 4 不同非线性模型修正方法的对比研究

为了验证改进的 GAN 在非线性模型修正方面的优越性,将所提出的方法与基于 CNN 的方法进行了对比。将计算的加速度响应中加入 5% 的高斯白噪声模拟实测数据,并从每组训练数据中选取 512 个样本点用于网络训练。其中,基于两类网络结构的非线性模型修正结果如表 8 和 9 所示。

由计算结果可知,在相同条件下,基于改进 GAN 的非线性参数修正结果更接近于真实值。此外,将修正后的非线性参数代入到框架模型中,得到

表 8 基于不同网络的混凝土材料参数修正误差

Tab. 8 The updated errors of concrete material parameters under different networks

网络模型	修正误差/%				
	$f_c$	$f_u$	$\epsilon_{\max}$	$\epsilon_u$	$f_t$
改进 GAN	2.61	1.22	-1.05	1.54	-1.83
CNN	0.42	1.39	1.54	2.50	-1.72

表 9 基于不同网络的钢筋材料参数修正误差

Tab. 9 The updated errors of reinforcement material parameters under different networks

网络模型	修正误差/%					
	$f_y^{\text{Col}}$	$E_s^{\text{Col}}$	$b^{\text{Col}}$	$f_y^{\text{B}}$	$E_s^{\text{B}}$	$b^{\text{B}}$
改进 GAN	-1.64	-1.43	-0.71	-3.75	1.74	-0.56
CNN	-4.04	-3.10	-1.91	-3.05	1.73	-0.83

两种非线性模型的预测误差如表 10 所示。由表 10 可知,基于改进 GAN 的非线性模型修正结果具有更高的精度。

表 10 基于不同网络的非线性模型修正误差对比

Tab. 10 Comparison of the updated errors of nonlinear model based on different networks

网络模型	修正误差/%		
	$E_{\text{acc}}^{(12)}$	$E_{\text{acc}}^{(10)}$	$E_{\text{disp}}^{(12)}$
改进 GAN	1.45	1.35	2.40
CNN	3.63	3.57	3.49

#### 5 实验验证

为了验证本文所提方法的可靠性,本节将对地震荷载作用下的悬臂铝梁振动台实验的非线性模型进行修正。实验装置如图 12 所示,悬臂铝梁结构的尺寸为 1000 mm×40 mm×3 mm。为了模拟结构的边界非线性,将直径为 18 mm 的圆形磁铁分别安装在支撑架和悬臂铝梁的自由端,通过在梁端利用磁铁之间的排斥力模拟结构在外部荷载作用下的非线性行为。实验过程中,利用 4 个加速度计测量结构在外荷载作用下的振动响应,采样频率设置为 300 Hz,加速度计和磁铁位置如图 12(b)所示。为了测试结构在地震荷载作用下的非线性行为,选用的外部地震荷载如图 13 所示,地震波的峰值加速度为 0.05g。在地震荷载作用下,获得的测点 A4 的加速度响应如图 14 所示。

磁铁之间的排斥力随着两块磁铁之间的相对距离而发生非线性变化,排斥力的振幅取决于磁铁之间的距离,两块磁铁的距离越近,非线性排斥力就越

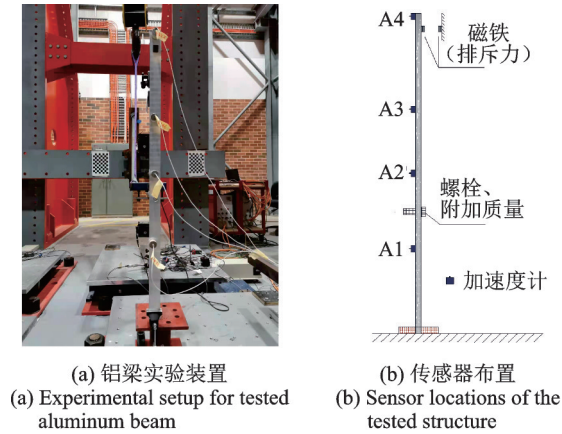


图 12 实验结构及传感器布置  
Fig. 12 The tested structure and sensor locations




图 13 外部荷载激励  
Fig. 13 The applied external excitation




图 14 测点 A4 的加速度响应  
Fig. 14 The acceleration response of the accelerometer A4

大,其作用可以用一个等效弹簧代替。因此,通过 OpenSees 有限元分析软件建立该实验结构的非线性模型,如图 15 所示。其中,梁端弹簧单元的非线性行为通过 Bouc-Wen 滞回模型<sup>[6]</sup>来定义,选取的 Bouc-Wen 滞回模型的参数初始值分别为  $\alpha=0.3$ ,  $\beta=150$ ,  $\gamma=150$ ,  $\delta_y=0.50$ ,  $\delta_v=0.25$ ,  $n=1.5$ 。

每个参数在原参数上下 30% 的范围内波动,基于拉丁超立方抽样随机产生 100 组参数组,选取 A1, A2, A3 加速度计测量的响应数据作为训练节点数据, A4 加速度计测量的响应数据作为验证节点数据进行网络训练,每个节点通道数据采样点数量为 512,利用训练好的网络模型进行参数识别,经计算,得到 Bouc-Wen 模型滞回参数的识别结果分别为  $\alpha=0.24$ ,  $\beta=180$ ,  $\gamma=140$ ,  $\delta_y=0.58$ ,  $\delta_v=0.22$ ,  $n=1.3$ 。然后,将识别出来的模型参数代入初始非线性模型中,利用修正后的非线性模型计算各节点在地震荷载作用下的加速度响应。考虑到振动响应的主






图 15 实验结构的非线性模型

Fig. 15 The nonlinear finite element model of the experimental structure

分量成分在表征结构非线性行为方面较为重要<sup>[6]</sup>,将测点 A2 和 A4 的加速度响应的一阶主分量与实测值进行对比,对比结果如图 16 所示。



(a) 测点 A2 的加速度响应主分量对比  
(a) The comparison of the main component of the decomposed acceleration response for accelerometer A2



(b) A4 测点的加速度响应主分量对比  
(b) The comparison of the main component of the decomposed acceleration response for accelerometer A4

图 16 修正后的非线性模型与实测结构的振动响应对比  
Fig. 16 The comparison of the vibration responses between the updated nonlinear model and the tested structure

由图 16 可知,修正后的非线性模型能够准确预测实验结构在地震荷载作用下的加速度响应,且预测效果较好。由等式(8)的计算结果可知,测点 A2 和 A4 的加速度响应误差指标计算值分别为  $E_{acc}^{(A2)}=9.46\%$ ,  $E_{acc}^{(A4)}=19.81\%$ 。通过与数值模拟对比可知,实验结构中的误差指标值要明显大于数值结构,主要原因可能是利用 Bouc-Wen 滞回模型定义结构的非线性边界存在较大的模拟误差;此外,在建模过程中,对结构线性参数的理想化也是造成预测误差的另一个重要因素。但总体来讲,利用本文所提出的

方法,能够可靠地对实验结构的非线性模型进行准确修正。

## 6 结 论

论文提出了一种基于改进GAN的结构非线性模型修正方法。利用该方法对地震荷载作用下的12层钢筋混凝土结构的非线性模型进行修正,并对不同噪声、不同采样点数量以及不同网络模型工况下的非线性模型修正结果的可靠性进行研究,最后,利用所提方法对地震荷载作用下的悬臂铝梁振动台实验结构的非线性模型进行修正,得到如下结论:

(1)本文所提出的改进GAN能够准确构建模型输入响应与输出参数之间的映射关系,并避免了传统GAN在训练过程中存在的梯度消失问题;

(2)基于改进GAN的非线性模型修正方法能够精确地实现地震荷载作用下的非线性模型修正,并具有较好的噪声鲁棒性;

(3)通过和基于CNN的非线性模型修正结果进行对比,进一步验证了本文所提出的非线性模型修正方法具有更高的预测精度。

### 参考文献:

- [1] 张皓,李东升,李宏男.有限元模型修正研究进展:从线性到非线性[J].力学进展,2019,49:542-575.  
Zhang H, Li D S, Li H N. Recent progress on finite element model updating: from linearity to nonlinearity[J]. Advance in Mechanics, 2019, 49: 542-575.
- [2] 袁平平,王佐才,任伟新.基于动力响应主分量瞬时频率和幅值的非线性模型修正[J].振动工程学报,2016,29(5):887-893.  
Yuan P P, Wang Z C, Ren W X. Nonlinear model updating based on instantaneous frequencies and amplitudes of principal dynamic response components[J]. Journal of Vibration Engineering, 2016, 29(5): 887-893.
- [3] 翁顺,朱宏平.基于有限元模型修正的土木结构损伤识别方法[J].工程力学,2021,38(3):1-16.  
Weng S, Zhu H P. Damage identification of civil structures based on finite element model updating[J]. Engineering Mechanics, 2021, 38(3):1-16.
- [4] 刘纲,罗钧,秦阳,等.基于改进MCMC方法的有限元模型修正研究[J].工程力学,2016,33(6):138-145.  
Liu G, Luo J, Qin Y, et al. A finite element model up-

dating method based on improved MCMC method[J]. Engineering Mechanics, 2016, 33(6):138-145.

- [5] Song M M, Renson L, Noël J P, et al. Bayesian model updating of nonlinear systems using nonlinear normal modes[J]. Structural Control and Health Monitoring, 2018, 25(12): e2258.
- [6] Wang Z C, Xin Y, Ren W X. Nonlinear structural model updating based on instantaneous frequencies and amplitudes of the decomposed dynamic responses[J]. Engineering Structures, 2015, 100: 189-200.
- [7] Lin K Q, Xu Y L, Lu X Z, et al. Time history analysis-based nonlinear finite element model updating for a long-span cable-stayed bridge[J]. Structural Health Monitoring, 2021, 20(5): 2566-2584.
- [8] 鲍跃全,李惠.人工智能时代的土木工程[J].土木工程学报,2019,52(5):1-11.  
Bao Y Q, Li H. Artificial Intelligence for civil engineering[J]. China Civil Engineering Journal, 2019, 52(5): 1-11.
- [9] Lin K Q, Xu Y L, Lu X Z, et al. Digital twin-based collapse fragility assessment of a long-span cable-stayed bridge under strong earthquakes[J]. Automation in Construction, 2021, 123: 103547.
- [10] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets[C]. Proceedings of the 27th International Conference on Neural Information Processing Systems. Cambridge, USA: MIT Press, 2014: 2672-2680.
- [11] Fan G, Li J, Hao H, et al. Data driven structural dynamic response reconstruction using segment based generative adversarial networks[J]. Engineering Structures, 2021, 234: 111970.
- [12] Fan G, Li J, Hao H. Dynamic response reconstruction for structural health monitoring using densely connected convolutional networks[J]. Structural Health Monitoring, 2021, 20(4): 1373-1391.
- [13] Pathak D, Krahenbuhl P, Donahue J, et al. Context encoders: feature learning by inpainting[C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA, 2016: 2536-2544.
- [14] 吕西林,李培振,陈跃庆.12层钢筋混凝土标准框架振动台模型试验的完整数据[R].上海:同济大学土木工程防灾国家重点实验室,2004:1-21.  
Lü X L, Li P Z, Chen Y Q. Benchmark test of a 12-story reinforced concrete frame model on shaking table [R]. Shanghai: State Key Laboratory of Disaster Reduction in Civil Engineering, Tongji University, 2004:



1-21.  
[15] 万华平,任伟新,王宁波.高斯过程模型的全局灵敏度分析的参数选择及采样方法[J].振动工程学报,2015,28(5):714-720.

Wan H P, Ren W X, Wang N B. A Gaussian process model based global sensitivity analysis approach for parameter selection and sampling method [J]. Journal of Vibration Engineering, 2015, 28(5): 714-720.

## Application of the improved generative adversarial network for nonlinear structural model updating

WANG Jun<sup>1</sup>, XIN Yu<sup>1,2</sup>, WANG Zuo-cai<sup>1,2,3</sup>, GE Bi<sup>1</sup>

(1.College of Civil Engineering, Hefei University of Technology, Hefei 230009, China; 2.Anhui Province Infrastructure Safety Inspection and Monitoring Engineering Laboratory, Hefei 230009, China; 3.Engineering Research Center of Safety-critical Industrial Measurement and Control Technology of the Ministry of Education, Hefei 230009, China)

**Abstract:** This paper proposes a nonlinear structural model updating approach based on the improved Generative Adversarial Network (GAN). In the improved GAN, the ability of the network discriminator to learn the response characteristics of nonlinear structures is enhanced by using the surrogate models. To avoid the problem that the gradient disappearance problem existing in traditional GAN, information exchange between network layers is strengthened by means of skip connection and dense connection, and a combined objective function is added to the improved GAN, whose aim is to construct the mapping relationship between structural responses and model parameters of a nonlinear structure to realize the network training. In nonlinear model updating, structural dynamic responses are considered as input of the network. After training, the constructed GAN network can predict the optimal value of nonlinear model parameters by learning the characteristics of input data, and the nonlinear model updating can be performed. To validate the feasibility of the proposed method, a 12-story reinforced concrete frame structure under earthquake excitations is conducted as numerical simulation, and the accuracy of the proposed method is further verified by comparing the results of nonlinear model modification based on convolutional neural network. Finally, the proposed method is applied to a nonlinear model updating of a cantilever beam shaking table experiment under earthquake excitation, and the same good updating results are achieved.

**Key words:** nonlinear model updating; improved generative adversarial network; nonlinear structure; network training

**作者简介:** 王 俊(1996—),男,硕士研究生。电话:(0551)62901461;E-mail: 2019170560@mail.hfut.edu.cn。

**通讯作者:** 王佐才(1982—),男,博士,教授。电话:(0551)62901461;E-mail: wangzuocai@hfut.edu.cn。