

DOI: 10.11883/bzycj-2023-0343

基于 PCA-BPNN 的桥梁爆炸荷载时程预测*

杜晓庆¹, 何益平¹, 邱涛¹, 程帅², 张德志²

(1. 上海大学力学与工程科学学院, 上海 200444;

2. 西北核技术研究所, 陕西 西安 710024)

摘要: 人工智能方法是预测爆炸荷载的新手段, 但现有方法主要用于预测爆炸冲击波的超压峰值或冲量, 而用于预测反射超压时程的研究不多。针对这一问题, 以平面冲击波绕射桥梁主梁为对象, 提出了一种基于主成分分析 (principal components analysis, PCA) 和误差反向传播神经网络 (backpropagation neural network, BPNN) 的桥梁爆炸冲击波反射超压时程预测模型。该预测模型利用 PCA 降维处理时程数据, 基于多任务学习的 BPNN 算法, 提出了考虑超压峰值和冲量峰值影响的损失函数, 使模型能有效预测不同入射超压下的桥梁冲击波荷载时程。通过分析多任务学习模型、多输入单输出模型和多输入多输出模型等 3 种 BPNN 模型, 发现多任务学习模型的预测精度最高, 而多输入多输出模型难以有效适应当前预测任务需求。采用多任务学习模型预测得到的桥梁表面各测点位置的反射超压时程、超压峰值精度较高, 决定系数 R^2 分别为 0.792 和 0.987, 作用在箱梁上的合力时程和扭矩时程预测值也与数值模拟值较为吻合。同时, 该模型对内插值预测的表现优于外推值预测, 但其在预测外推值方面同样展现出了一定的能力。

关键词: 爆炸荷载预测; 反射超压时程; 误差反向传播神经网络; 主成分分析; 多任务学习

中图分类号: O383

国标学科代码: 13035

文献标志码: A

Prediction of blast loads on bridge girders based on PCA-BPNN

DU Xiaoqing¹, HE Yiping¹, QIU Tao¹, CHENG Shuai², ZHANG Dezhi²

(1. School of Mechanics and Engineering Science, Shanghai University, Shanghai 200444, China;

2. Northwest Institute of Nuclear Technology, Xi'an 710024, Shaanxi, China)

Abstract: Facing the challenges on the accurate and effective prediction under extreme loads, machine learning has gradually demonstrated its potential to replace traditional methods. Existing approaches primarily focus on predicting the peak overpressure or impulse of explosive shock waves, with limited research on predicting the reflected overpressure time history. Load-time history prediction encompasses not only the peak overpressure but also embraces various multi-dimensional information including duration, waveform, and impulse, thereby offering a more comprehensive depiction of the dynamic temporal and spatial characteristics of shock waves. To address this issue, a prediction model for bridge surface reflected overpressure time history is proposed, targeting a planar shock wave diffracting around a bridge section. This model is based on principal component analysis (PCA) and back propagation neural network (BPNN) algorithm with multi-task learning. A loss function considering the impact of peak overpressure and maximum impulse is introduced to fully consider the potential correlations between different modes after PCA dimension reduction. This enables the model to effectively predict bridge shock wave load time histories under varying incident overpressure. Through the analysis of three types of BPNN models, multi-task learning model, multi-input single-output model, and multi-input multi-output model. It was found that the multitask learning model has the highest prediction accuracy, while the multi-input multi-output model struggles to effectively adapt to the current predictive task requirements. The multitask learning model, used for predicting, achieves high precision in

* 收稿日期: 2023-09-26; 修回日期: 2024-04-19

第一作者: 杜晓庆 (1973—), 男, 博士, 教授, dxq@shu.edu.cn

通信作者: 邱涛 (1994—), 男, 博士, qiutao@shu.edu.cn

forecasting the time history of reflected overpressure at various measurement points on the bridge surface and the peak overpressure values, with R^2 values of 0.792 and 0.987. It also closely matches the simulation values in predicting the time history of combined forces and torque acting on the box girder. Additionally, this model performs better in interpolative value prediction than in extrapolative value prediction, but it also demonstrates a certain capability in predicting extrapolative values.

Keywords: explosion load prediction; reflected overpressure time history; back propagation neural network; principal components analysis; multi-task learning

近年来,由于工业事故引发了一系列大规模爆炸事件,其影响范围广泛,达到了几千米甚至数十千米,因此远场大爆炸问题一直受到学术界和工程界的广泛关注^[1-3]。桥梁结构作为基础设施中的重要组成部分,承受着来自自然灾害、交通负荷以及人为事故等多种外部负荷的挑战。准确预测爆炸冲击波反射超压时程,对于分析结构动力响应和开展结构损伤评估具有重要意义^[4]。远场冲击波持续时间长、冲量较大,对结构的影响显著而深远,不仅会导致局部的破坏,也可能引起全局的结构响应。与单一峰值压力或冲量相比,冲击波荷载时程包含了更多的信息,如荷载超压峰值、持续时间、波形、冲量^[5]等,这些信息更能够反映出冲击波荷载在时间和空间上的变化特性,仅预测超压峰值已不能满足现有需求,如何快速而准确地预测爆炸冲击波反射超压时程,仍然是一个具有挑战性的问题。

经验公式和计算流体力学(computational fluid dynamics, CFD)方法是研究爆炸荷载的重要方法。Kingery 等^[6]提出了一种半经验方法来预测球形炸药爆炸产生的球形波的自由场超压时程,然而,这个方法只在远场爆炸和自由场环境中才能取得精确结果^[7]。复杂环境中的爆炸会产生非线性的多重冲击波,它们在障碍物上反射或绕过障碍物而产生合并,使得简单的叠加方法变得不再适用^[8-9]。CFD 具有准确模拟爆炸荷载的潜力,已被广泛应用于对爆炸荷载的模拟^[10-12]。然而,复杂的几何结构加剧了计算成本,从而削弱了 CFD 方法在这种情况下优势。为解决这些问题,机器学习方法因其在处理大量数据、发现复杂非线性关系以及提供准确预测方面的优势而在爆炸荷载预测中引起了广泛关注^[13],在针对某些特定问题时往往可以起到不错的效果。

高保真模型模拟、试验数据或两者与机器学习技术的结合已被证明可以为非理想的爆炸环境提供快速而可靠的结果^[14]。Remennikov 等^[15]和 Bewick 等^[16]通过人工神经网络较为准确地预测了爆炸冲击波在有屏障阻挡的情况下的自由场超压峰值。Alshammari 等^[17]通过研究证明了人工神经网络(artificial neural network, ANN)可以显著提高预测复杂条件下目标反射超压峰值的能力。Pannell 等^[18]研究了神经网络在爆炸保护工程中的应用,通过引入物理信息提高了模型的预测性能。后续又使用迁移学习来改进自由场超压峰值的预测^[19]。Li 等^[20]通过比较 4 种机器学习算法,包括集成树方法及 3 种其他类型的神经网络,并通过预测沸腾液体膨胀蒸汽爆炸压力来展示不同机器学习算法在自由场超压峰值预测中的有效性。在爆炸冲击波时程预测领域, Li 等^[21]通过 7 个 Transformer 模型,针对爆炸冲击波时程的 7 个关键参数进行了专门的训练和调整,从而实现了爆炸冲击波反射超压时程的重构。Huang 等^[22]通过深度学习技术,利用低分辨率的流场信息,对二维爆炸压力场进行了超分辨率重构,实现了对爆炸冲击波反射超压的预测。此外,孙传猛等^[23]采用深度卷积神经网络结合双向长短期记忆网络,成功重构了自由场爆炸冲击波信号,其研究结果突出了深度学习技术在捕捉和分析时序数据特征方面的强大能力。综上所述,机器学习在爆炸荷载预测方面已展现出广泛的应用潜力,但目前大多数研究都关注自由场爆炸环境和近场爆炸的超压峰值和冲量,现有的关于爆炸冲击波反射超压时程计算公式只考虑了入射角和入射超压的影响,对于复杂构件表面爆炸冲击波反射超压时程无法提供精确的计算结果。

基于上述考虑,同时为避免复杂的建模过程,本文以平面冲击波绕射桥梁主梁为对象,提出一种融合误差反向传播神经网络(backpropagation neural network, BPNN)和主成分分析(principal components analysis, PCA)的爆炸冲击波反射超压时程快速预测模型。采用 PCA 方法对时程降维处理,基于多任务学习的 BPNN 算法,结合问题特点,提出考虑超压峰值和冲量峰值影响的损失函数,以期能够使模型有效预测不同入射超压下的桥梁爆炸反射超压时程。

1 数据来源

本文中研究数据来源于 CFD 数值模拟计算。如图 1 所示, S-1~S-6 为箱梁表面典型位置。选用箱型梁桥为对象, 在箱梁表面布置了 70 个反射超压测点。单个测点采样频率为 100 kHz, 采样时间为 150 ms, 共记录了 15 000 个时间步。冲击波的入射方向、合力(F_x 、 F_y)和扭矩(T)方向如图所示。数值模拟的入射超压分别为 $p_{i,max}=0.1, 0.3, 0.5, 0.8, 1.0, 1.5$ MPa。将 $p_{i,max}=0.1, 0.5, 1.0$ MPa 的箱梁表面各测点压力时程数据作为训练集和验证集, $p_{i,max}=0.3, 0.8, 1.5$ MPa 的数据作为测试集。




图 1 主梁表面测点布置示意图

Fig. 1 Schematic diagram of surface measurement points layout on the main beam

图 2 为平面冲击波绕射的 CFD 数值模拟计算域, 计算域的入口采用压力入口边界条件, 出口采用无反射出口边界条件, 上下两侧壁面采用对称的无滑移壁面边界条件。为了确保计算结果的正确性, 针对网格尺寸和计算时间步开展了参数敏感性分析, 并与激波管试验数据进行了比较^[24], 确定的计算参数为: 自由场网格尺寸为 4 mm, 近壁面最小网格厚度为 0.05 mm, 时间步长为 1 μ s。图 3 给出了自由场超压与动压时程的数值模拟结果与试验结果的对比, 以及超压峰值为 250 kPa 的 Friedlander 波^[25] 的拟合情况。在 Friedlander 波的拟合中, 使用以下计算公式来描述超压随时间的变化:

$$p_i(t) = p_{i0} \left(1 - \frac{t}{t_0} \right) e^{-b \frac{t}{t_0}} \quad (1)$$

式中: $p_i(t)$ 为 t 时刻的超压, p_{i0} 为超压峰值, t_0 为正压持续时间, b 为衰减系数。




图 2 计算域与边界条件

Fig. 2 Computational domain and boundary conditions




图 3 自由场超压时程曲线

Fig. 3 Free-field overpressure time history curves

在数值模拟和试验中, 超压峰值分别为 256 和 264 kPa, 相对误差为 3%; 数值模拟和试验动压峰值分别为 171 和 192 kPa, 相对误差为 10.9%。结果表明, CFD 数值模拟结果与试验结果吻合良好, 本文中的模拟方法和参数对冲击波作用下桥梁爆炸荷载的预测是准确可靠的。

2 方法与实现

对不同入射超压下箱梁表面 70 个测点的反射超压时程数据, 采用 PCA 和 BPNN 结合的方法, 实现不同入射超压下荷载时程的预测。预测方法流程如图 4 所示, 主要分为 PCA 数据降维、模型训练和模型预测等 3 个环节。

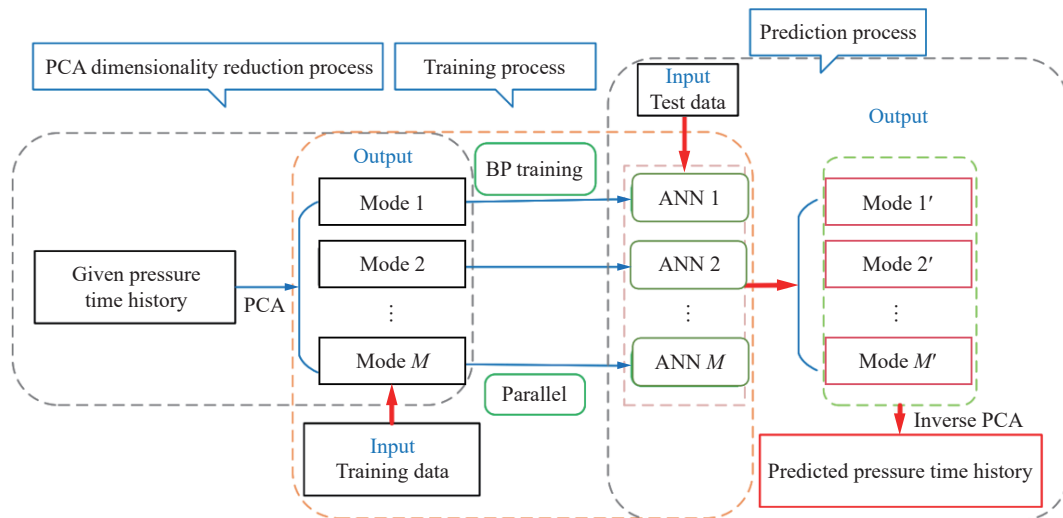


图 4 PCA-BPNN 训练和预测流程图

Fig. 4 Process of training and predicting for PCA-BPNN

2.1 PCA 数据降维

PCA 是一种被广泛采用的降维技术, 其核心思想是将原始数据集映射到一个新的特征空间, 以确保在这一新空间中的数据点能够尽可能地保留原始数据集的最大方差。主成分分析得到的主成分是一组正交基, 它们的主要作用是最大限度地保留原始数据集中的关键信息。方差解释率是每个主成分所对应的方差与所有主成分方差之和的比值。通常可通过累积方差解释率来确定需要选取多少个主成分, 以充分捕捉数据的变异性。

图 5 展示了累积方差解释率随主成分数量变化的趋势。可见仅前 40 个主成分就已累积了 99.9% 的方差。考虑到数据集包含长时程数据, 直接用 BP 网络处理会导致输出困难。通过引入 PCA 技术, 能将模型的输入数据有效压缩到 40 维, 这一降维策略极大地简化了数据结构, 从而使得 BP 神经网络能够更有效地处理这些数据。然而, PCA 降维依赖所用数据集的特性意味着, 一旦数据集发生变化, 之前选定的正交基可能不再适用, 需要重新调整以适应新的数据特征。由于本文中所采用的数据集均源自单一箱梁截面形式下的反射超压时程。因此, 采用 PCA 技术对数据集进行了降维处理, 并验证了由此得到的正交基是否适用于多种箱梁截面的反射超压时程数据。包括了在爆炸冲击波作用下, 不同入射角度以及不同箱梁截面的梁宽和梁高条件下, 箱梁表面反射超压时程数据的重构效果。如图 6 所示, 当利用前 40 个主成分进行数据重构测试时, 各数据集在经过 PCA 降维及随后的数据重构后, 其时程数据与原始数据之间的决定系数均接近 0.95, 这一结果证实了本文中所提出方法的有效性和适用性。未来可通过对更大和更多样化的数据集进行训练和测试, 来进一步增强 PCA 方法的泛化能力和稳健性。




图 5 累积方差解释率随主成分数量的变化

Fig. 5 Variation of cumulative variance contribution with the number of principal components

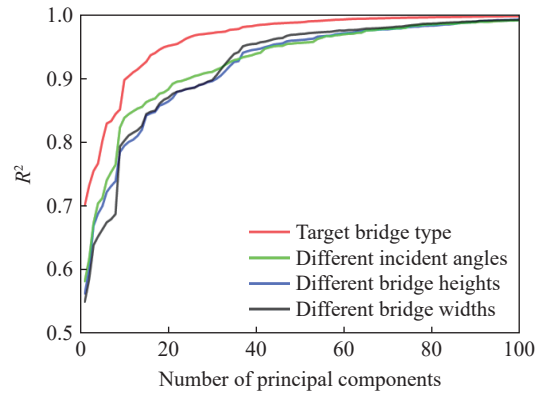


图 6 R^2 随主成分数量的变化

Fig. 6 Variation of R^2 with the number of principal components

2.2 BP 神经网络模型选取

2.2.1 多输入多输出模型

多输入多输出模型(见图 7)可以同时处理多个输入和多个输出。在本文中,冲击波入射超压和箱梁表面测点位置信息作为网络输入,荷载时程 PCA 降维后各个主成分模态作为网络输出。这种模型可以学习不同目标变量之间的相关性,从而提高模型对目标之间复杂关系的建模能力。

2.2.2 多输入单输出模型

与多输出神经网络不同,多输入单输出模型(见图 8)的输出层仅有一个输出节点。该模型的输出是将各个主成分模态分别代入网络训练,确保每个主成分模态都能得到充分的训练。这种模型减少了网络的复杂性和训练的难度,但降低了模型的训练效率。




图 7 多输出反向传播神经网络

Fig. 7 Multi-output BPNN




图 8 单输出反向传播神经网络

Fig. 8 Single-output BPNN

2.2.3 多任务学习模型

多任务学习模型可以同时处理多个相关任务。在本文中,针对每个主成分模态分别建立单输出神经网络模型,基于多任务学习策略并行训练。通过重新定义的损失函数,模型可以学习不同主成分之间的内在关系,从而提高预测的准确性和鲁棒性。训练过程的详细步骤如图 4 所示。

2.3 实施步骤

2.3.1 数据预处理

由于箱梁表面爆炸荷载的复杂性,本文中选用入射超压 $p_{i,max}$ 、测点坐标 x 和 y ,以及测点所处面法线方向与入射冲击波入射方向的夹角 θ 和测点到壁面的距离 D 作为网络的输入。反射超压时程 t 作为网

络的输出。对输入数据进行标准化处理。为更好理解输入参数对输出结果的影响,图 9 中采用热力图形式展示了输入变量和输出变量之间的 Pearson 相关系数。Pearson 相关系数是介于 $-1 \sim 1$ 的值,用于衡量两个变量之间的线性相关度。其中,1 代表完全正相关,0 表示无相关性,而 -1 表示完全负相关。可见,入射超压 $p_{i,max}$ 与 t 具有最正相关的关系,而夹角 θ 与 t 具有最负相关的关系。

2.3.2 超参数调整

机器学习模型的性能在很大程度上取决于一组最优的超参数组合。为了对模型进行有效比较,本文中采用了一种基于贝叶斯优化的高级超参数搜索技术,对神经网络的隐藏层数量、各层神经元数、激活函数以及正则化参数进行了细致的搜索。这种方法不仅能够在超参数空间中进行全面探索,而且能够依据先前试验的反馈,智能选择下一组待评估的超参数,以此优化模型的性能。相较于传统的网格搜索和随机搜索,贝叶斯优化展现出更高的效率和精确度。它能够在有限的调优资源下,精准定位到最优超参数组合,进而显著提升模型的性能。在本文中,每个模型都经过了 200 次不同的超参数组合的调优过程,最终选择在验证集上表现最佳的超参数组合,以确保找到每个模型的最佳超参数配置,从而提高其性能并确保结果的可靠性。

2.3.3 模型训练

神经网络的最大迭代次数为 2000 次,批次大小为 32,以确保模型有足够的学习和收敛时间,从而提高预测性能。同时,设置了提前停止机制。当模型在验证集上连续 100 次迭代后性能未显著提升时,训练过程将提前终止,以避免模型过拟合。另外,为了评估模型的性能和稳定性,采用了五折交叉验证的方法。该方法将训练数据集随机划分为 5 个等大小的子集,每次迭代中 4 个子集被用于模型训练,而剩余的一个子集则作为验证集。如图 10 所示,通过这种交叉验证策略,模型在不同数据子集上的表现得到了多次评估,从而降低了评估结果的随机性,并增强了模型性能评估的可靠性。通过 5 次迭代,每个数据点均有机会作为验证数据参与评估,而其余 4 次则作为训练数据,确保了模型评估的全面性和公正性。最终,通过计算 5 次验证结果的平均值,得出模型的综合性能指标,降低评估结果的随机误差。

2.3.4 评价指标

为了对模型进行全面比较,采用了均方根误差(root mean square error, RMSE)、平均绝对误差(mean absolute error, MAE)、平均绝对百分比误差(mean absolute percentage error, MAPE)和决定系数(R^2)等 4 个评价指标进行模型精度评估^[26]。

RMSE 是衡量预测值与真实值之间差异的标准差,可以量化预测误差的散布程度。RMSE 的值越小,表示模型的预测能力越好。计算公式如下:

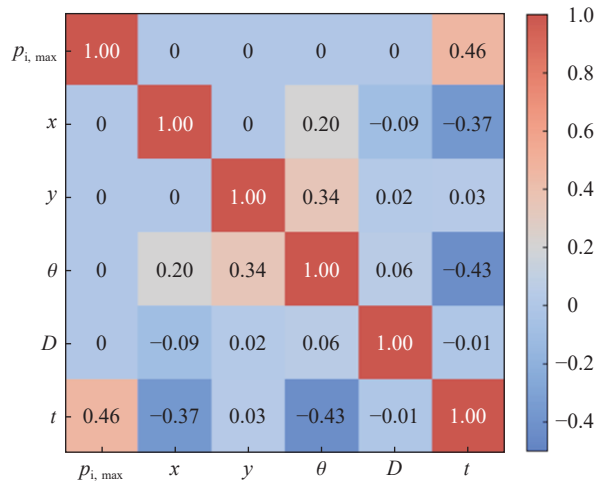


图 9 输入输出变量之间的相关矩阵

Fig. 9 Correlation matrix between input and output

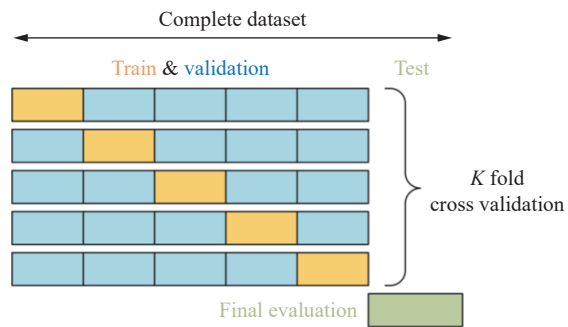


图 10 K 折交叉验证示意图

Fig. 10 Schematic diagram of K-fold cross-validation

$$\varepsilon = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (2)$$

式中: N 为数据点的数量, y_i 为真实值, \hat{y}_i 为预测值。

MAE 是预测值与真实值之间绝对差异的平均值, 与 RMSE 相比, MAE 对异常值不敏感, 更加关注预测值的平均误差。较小的 MAE 值表示模型的精度较高。计算公式如下:

$$\delta = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (3)$$

MAPE 为预测值与真实值之间差异的百分比的平均值, 可以帮助评估模型在不同值范围下的预测准确性。计算方式如下:

$$\eta = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (4)$$

不同于 MAPE 从局部度量预测误差, 决定系数 (R^2) 衡量了模型预测值与真实值之间的线性相关程度。它表示模型能解释因变量变异程度的比例。决定系数 R^2 的取值范围为 $0 \sim 1$, 越接近 1 表示模型的预测能力越好。在某些情况下, 当模型的预测效果比简单预测平均值差时, 决定系数可能为负。计算公式如下:

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (5)$$

式中: $\bar{y} = \frac{1}{N} \sum_{i=1}^N y_i$ 为真实值的均值。

在时间序列预测中, 高 R^2 值意味着模型能够准确捕捉到时间序列数据的变化趋势, 这是判断模型预测效果优劣的重要依据。因此, 本文中模型训练着重于提高 R^2 值, 旨在确保模型能够准确预测爆炸冲击波反射超压时程。

2.4 损失函数

损失函数是评估模型预测结果与真实值之间差异的关键指标, 通过最小化损失函数, 可以优化模型的预测性能。在多任务学习模型中, 为了综合考虑超压峰值和冲量峰值对模型预测性能的影响, 构建了以下损失函数:

$$L_{\text{sum}} = L_{\text{pca}}(\hat{Y}, Y) + \lambda_1 L_{\text{peak}}(\hat{Y}, Y) + \lambda_2 L_{\text{impulse}}(\hat{Y}, Y) \quad (6)$$

式中: $L_{\text{pca}}(\hat{Y}, Y)$ 为各主成分模态的真实值和预测值之间的误差, $L_{\text{peak}}(\hat{Y}, Y)$ 为超压峰值误差, $L_{\text{impulse}}(\hat{Y}, Y)$ 为冲量峰值误差。采用贝叶斯优化算法对取值范围为 $0 \sim 10$ 和 $0 \sim 1$ 之间随机分布的浮点数 λ_1 和 λ_2 进行超参数搜索。这个优化过程确保了权重的合理性和最佳性能, 有助于提升模型的预测准确性和鲁棒性。

2.5 模型选取

表 1~3 详细列出了各模型在测试集上关于反射超压峰值、冲量峰值以及超压时程曲线的各项评价指标。为了降低模型随机性对结果的影响, 对每个模型进行了 10 次独立的运行, 并在计算平均值之前去除了最大值和最小值。由预测结果可知, 在预测爆炸冲击波反射超压峰值、冲量峰值和反射超压时程曲线这 3 个关键指标上, 多任务学习模型表现最佳, R^2 分数分别达到 0.987、0.958 和 0.792。

多输出模型最初被选用是为了同时处理 PCA 分解后的多个主成分模态。但在实际应用中发现该模型在同时处理多个模态时的性能并不理想。相比之下, 其网络复杂度要远小于其他两种模型, 难以匹配当前训练任务的需求。多输入单输出模型在各项指标上也表现出良好的性能, 但该模型仅考虑了各

主成分模态的误差,未引入额外的冲击波时程特征,而且由于模型需要对各个主成分模态进行单独的循环训练,因此导致其训练时间大约是多任务学习的 7 倍。多任务学习的提出旨在结合多输出模型和单输出模型的优势。该模型不仅能够同时处理各个主成分模态,而且提高了对每个主成分模态的训练精度。多任务学习模型考虑了多个主成分模态的误差,并通过特别设计的损失函数,能够同时关注时程信息中的关键特征,并提供对于不同任务(如预测峰值、冲量等)的专注性能,同时保持计算效率。

表 1 超压峰值的各模型预测评价指标

Table 1 Evaluation metrics for peak overpressure prediction models

预测模型	RMSE	MAE	MAPE	R^2
多输出模型	1.089	0.788	3.105	-0.386
单输出模型	0.152	0.092	0.220	0.976
多任务模型	0.115	0.074	0.180	0.987

表 2 冲量峰值的各模型预测评价指标

Table 2 Evaluation metrics for peak impulse prediction models

预测模型	RMSE	MAE	MAPE	R^2
多输出模型	3.970	2.822	0.554	-0.403
单输出模型	0.866	0.646	0.133	0.934
多任务模型	0.693	0.542	0.109	0.958

表 3 超压时程曲线的各模型预测评价指标

Table 3 Evaluation metrics of overpressure time-history prediction models

预测模型	RMSE	MAE	MAPE	R^2
多输出模型	0.173	0.068	-	-5.466
单输出模型	0.069	0.015	-	0.753
多任务模型	0.065	0.014	-	0.792

3 预测结果与精度分析

在本节中,将分析多任务学习模型在冲击波预测的多个方面性能。通过使用入射超压 $p_{i,max}=0.1, 0.5, 1.0$ MPa 下箱梁表面各测点反射压力时程数据进行训练,预测两个内插强度(0.3 和 0.8 MPa)以及外推强度(1.5 MPa)下的桥梁表面反射超压时程。基于这些预测结果,进一步计算得出反射超压峰值分布、合力和扭矩时程曲线。本文中,神经网络模型包含两个隐藏层,每层分别配置了 16 和 80 个神经元,激活函数选用了 Mish 函数^[27],优化器则选择了 Nadam。此外,神经网络的训练批次大小设定为 32,损失函数的权重分别设置为 2.0 和 0.2,以优化模型性能。

3.1 反射超压时程预测

图 11~13 给出了在入射超压分别为 0.3、0.8 和 1.5 MPa 时,箱梁表面典型位置(见图 1 的 S-1~S-6)的反射超压时程和冲量时程曲线的数值模拟、模型预测及基于 Friedlander 经验公式的对比结果。由图 11~13 可见,预测值与数值模拟结果基本一致,其中,超压和冲量峰值以及冲击波到达时间均展现了较高的预测精度。基于经验公式在理想状态下计算得出的时程曲线与数值模拟结果相比,在迎爆面和侧面反射超压峰值拟合效果较好,在背爆面反射超压峰值计算结果偏大,且迎爆面冲量被显著高估。与此同时,经验公式计算出的时程曲线形式过于标准化,难以匹配复杂流场情况下的反射超压时程曲线。由表 4 可知,在复杂的流场环境下,传统的经验公式计算难以实现准确预测,超压时程曲线的 R^2 均为负值。本

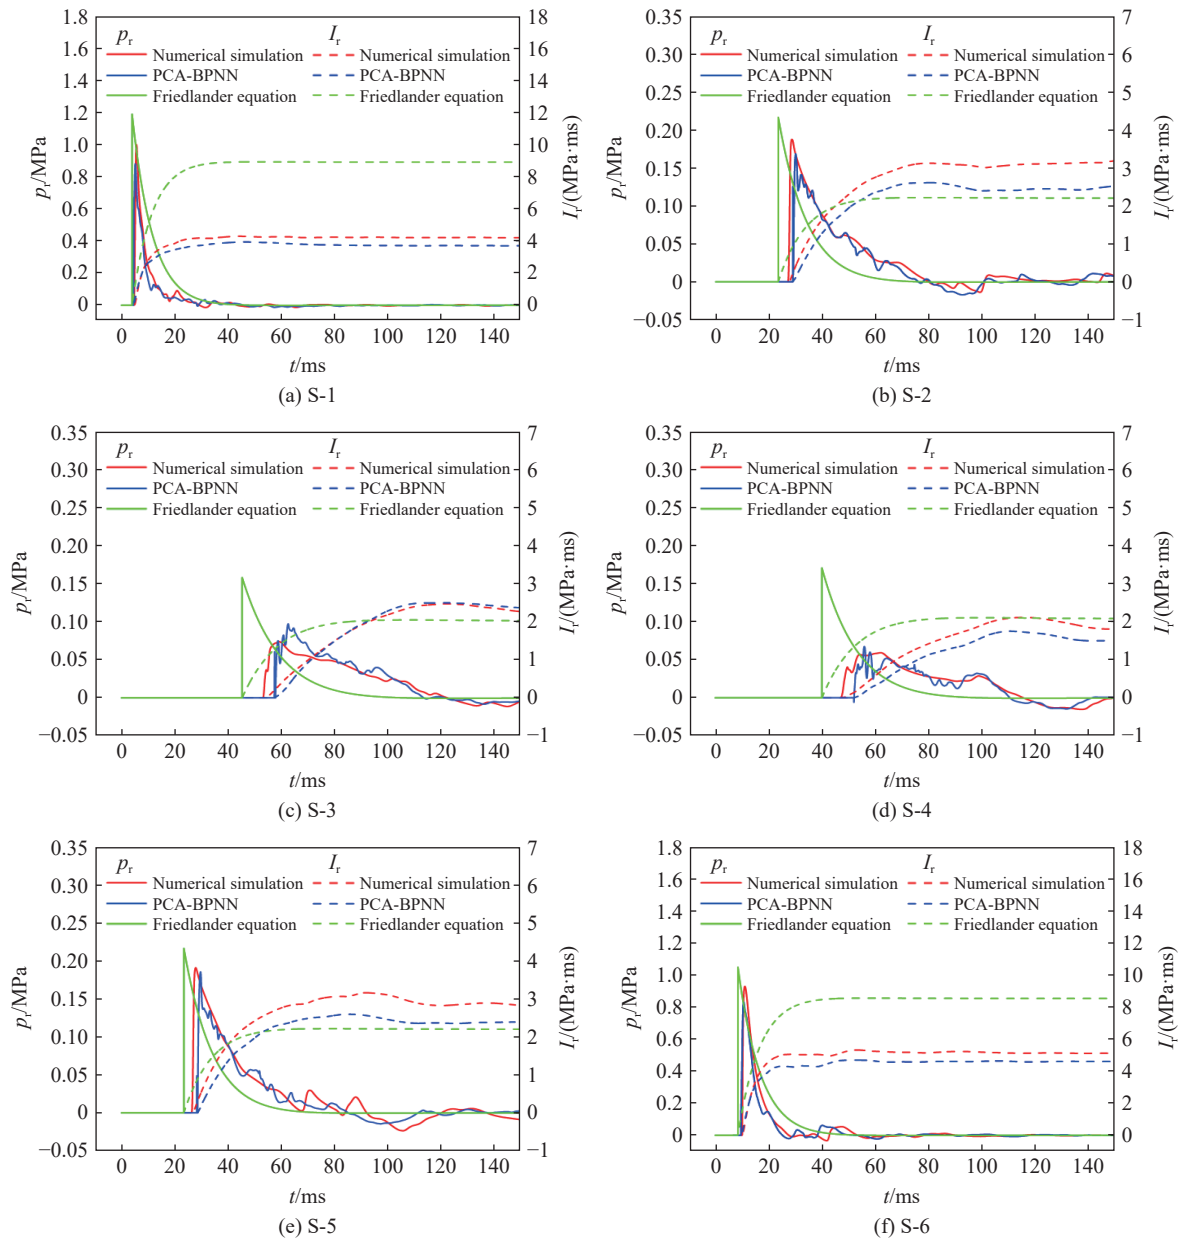
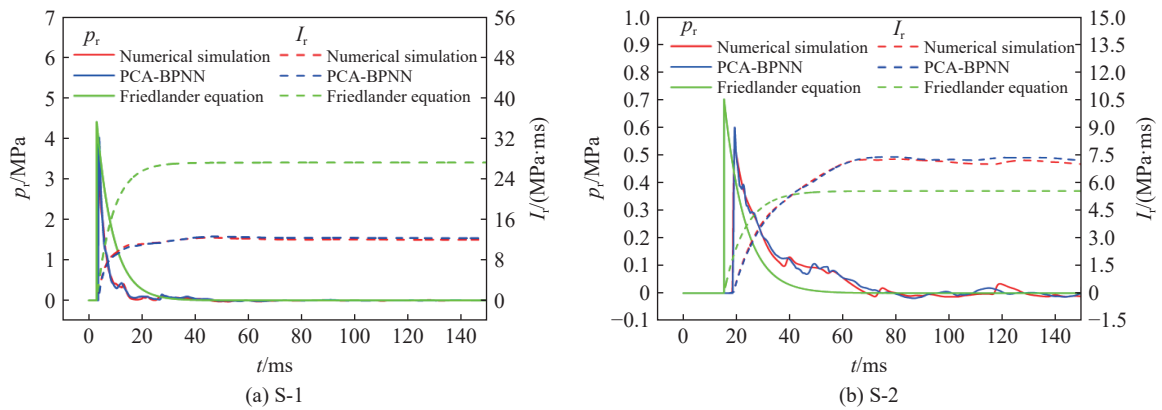


图 11 入射超压 0.3 MPa 下测点的反射超压和冲量时程曲线

Fig. 11 Reflected overpressure and impulse time histories at measurement points under 0.3 MPa incident overpressure



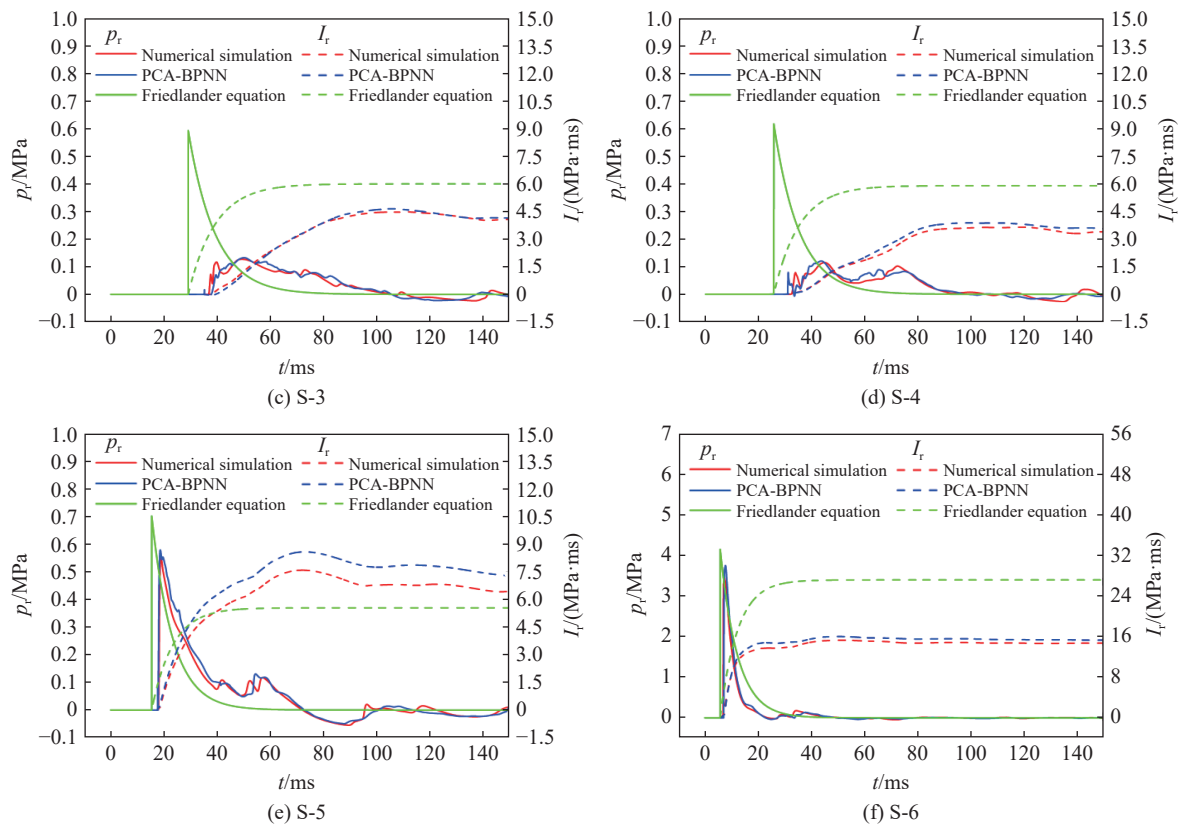
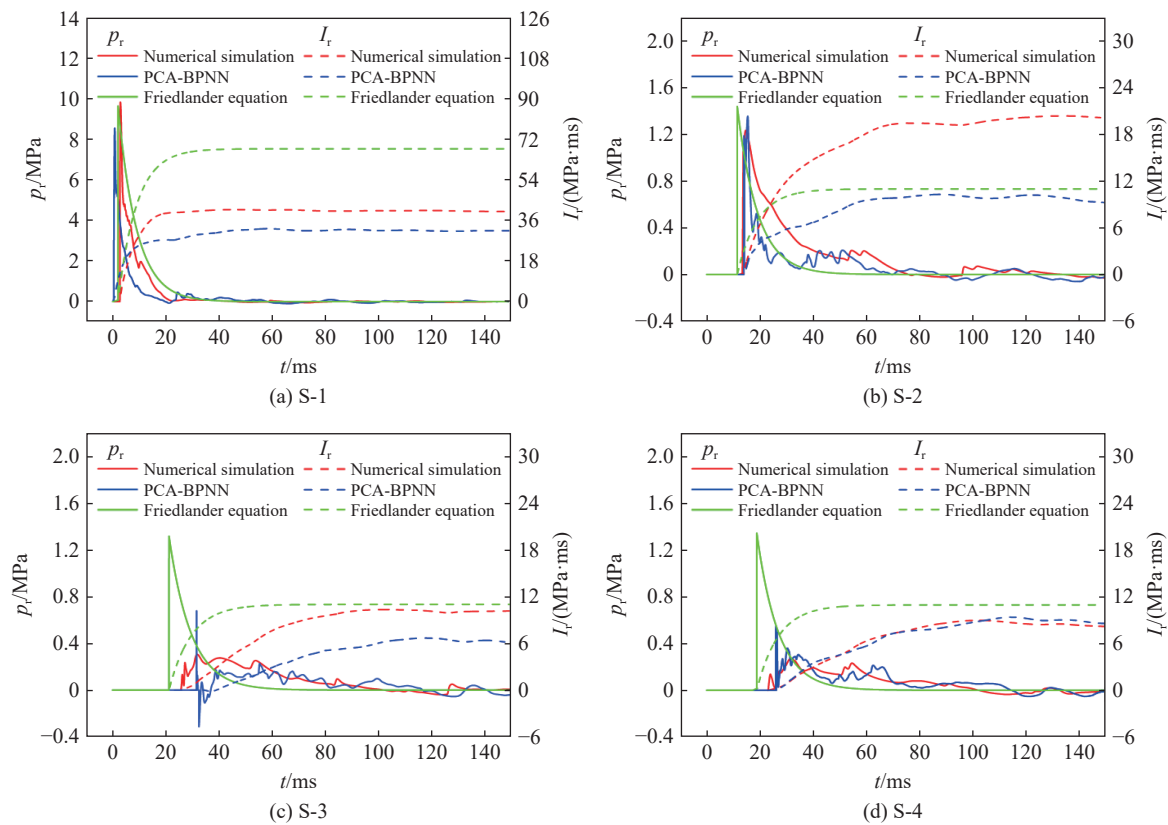


图 12 入射超压 0.8 MPa 下测点的反射超压和冲量时程曲线

Fig. 12 Reflected overpressure and impulse time histories at measurement points under 0.8 MPa incident overpressure



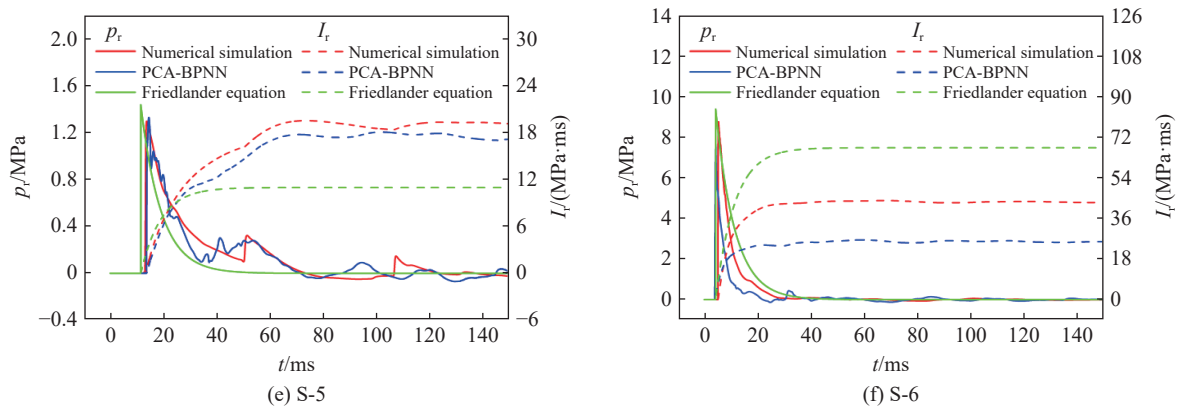


图 13 入射超压 1.5 MPa 下测点的反射超压和冲量时程曲线

Fig. 13 Reflected overpressure and impulse time histories at measurement points under 1.5 MPa incident overpressure

文中提出的预测模型在解决桥梁爆炸冲击波反射超压时程预测方面展现了显著优势,有效弥补了经验公式的不足。

表 4 模型预测误差及经验公式计算误差对比

Table 4 Comparison of model prediction error and empirical formula calculation error

方法	$p_{i,max}=0.3\text{ MPa}$		$p_{i,max}=0.8\text{ MPa}$		$p_{i,max}=1.5\text{ MPa}$	
	超压时程的 R^2	最大冲量的MAPE	超压时程的 R^2	最大冲量的MAPE	超压时程的 R^2	最大冲量的MAPE
PCA-BPNN	0.81	0.124	0.92	0.052	0.46	0.262
经验公式	-0.33	0.410	-2.05	0.573	-1.42	0.396

此外,从 1.5 MPa 入射超压的预测结果可知,模型展现了超出训练范围的预测能力。这表明模型在处理训练范围之外的数据时,具有潜在的学习能力,能够理解冲击波荷载时程的复杂动态规律,包括时间和空间上的变化,以及与各种不同入射超压之间的关系。

3.2 合力与扭矩时程

为了进一步比较箱梁桥截面上的合力和扭矩的数值模拟与模型预测结果,将箱梁表面所有测点的压力合力分解为沿冲击波方向的横向合力 F_x 和垂直于冲击波方向的纵向合力 F_y ,各测点压力与质心距离的乘积之和定义为扭矩 T 。图 14~16 给出了不同入射超压下箱梁上合力和扭矩的时程曲线。由图中可知,在内插强度为 0.3 和 0.8 MPa 的情况下,模型对合力和扭矩的预测值精度较高,在外推强度为 1.5 MPa 时,预测值远超模型训练范围内,从而导致模型预测精度有所降低。这一结果强调了模型在处理超出训练数据范围的外推任务时的局限性,同时也指出了未来优化模型泛化能力的潜在方向。




图 14 入射超压 0.3 MPa 下箱梁的合力和扭矩时程曲线

Fig. 14 Resultant force and torque time histories of box girder under 0.3 MPa incident overpressure




图 15 入射超压 0.8 MPa 下箱梁的合力和扭矩时程曲线

Fig. 15 Resultant force and torque time histories of box girder under 0.8 MPa incident overpressure




图 16 入射超压 1.5 MPa 下箱梁的合力和扭矩时程曲线

Fig. 16 Resultant force and torque time histories of box girder under 1.5 MPa incident overpressure

3.3 反射超压峰值

图 17~18 给出了基于反射超压时程预测结果得到的超压峰值精度分析。在图 17 中, 红色实线代表理想预测线, 即预测结果与数值模拟值完全一致; 黄色虚线表示相对误差为 30% 的误差边界; 横坐标为数值模拟超压峰值 p_r , 纵坐标为模型预测值 p'_r 。由图可知, 在入射超压为 0.3 和 0.8 MPa 时, 超压峰值预测的准确性较高, 几乎所有超压峰值预测值都落在 30% 的相对误差边界内, 对应的平均绝对百分比误差分别为 13.79% 和 7.70%。然而, 对于远超训练范围的 1.5 MPa 入射超压, 预测精度有所下降, 其平均绝对百分比误差上升至 65.99%。




图 17 不同入射超压下模型超压峰值预测拟合曲线

Fig. 17 Model overpressure peak prediction fit graph under different incident overpressures

在图 18 中, 红色实线表示箱梁结构表面反射超压峰值的数值模拟结果, 蓝色实线表示模型预测结果, 图中各处标记的数值表示该位置测点处超压峰值的数值模拟和模型预测值之间的平均误差。结合图 18 中箱梁表面反射超压峰值与模型预测值分布及平均相对误差的对比, 可以明显观察到预测模型的主要误差集中在箱梁截面的角点区域。尽管存在这些局部误差, 从整体上看, 模型的预测精度较高。




图 18 超压峰值的数值模拟值与预测值对比

Fig. 18 Comparison of peak overpressure between numerical simulation and predictive values

4 结 论

本文中以平面冲击波绕射桥梁断面为对象, 提出了一种基于主成分分析和误差反向传播神经网络的爆炸冲击波反射超压时程预测模型, 重点关注了桥梁爆炸冲击波反射超压时程、合力时程和弯矩时程等参数, 以获取精细全面的爆炸荷载分布, 并得出了以下结论。

(1) 通过对不同神经网络的详细比较分析, 发现多任务学习模型在预测桥梁荷载时程方面表现出显著的优势。结合问题特点提出了考虑超压峰值和冲量峰值影响的损失函数, 使模型能够更全面地捕捉并利用关键参数之间的相关性, 从而提升预测性能。

(2) 时程预测能更全面地反映冲击波在时间和空间上的变化特征。针对典型位置测点的反射超压时程预测结果精度较高, R^2 为 0.792。此外, 基于时程预测结果计算得出的超压峰值分布、合力和扭矩时程与数值模拟结果较为吻合, 充分证明了模型的可靠性和准确性。

(3) 多任务学习模型在内插值预测方面展现出了卓越的性能, 对入射冲击波超压峰值为 0.3 和 0.8 MPa 的桥梁爆炸冲击波反射超压时程预测准确性较高, 其决定系数 R^2 分别为 0.81 和 0.92。同时, 在外推值预测方面也表现出了一定的能力, 进一步证明了该模型具备深入理解和学习爆炸波传播内在规律的潜力。

当前研究的模型主要针对特定的箱梁截面进行训练和预测。为了增强模型的泛化能力和适用性, 未来的研究将着重于构建一个更全面的平面冲击波作用下梁桥荷载数据库。也计划引入更多的输入参数和特征, 以更全面地描述冲击波的影响因素, 从而提高模型在工程设计和风险评估等领域的实际应用价值。

参考文献:

- [1] CLUBLEY S K. Non-linear long duration blast loading of cylindrical shell structures [J]. *Engineering Structures*, 2014, 59: 113–126. DOI: 10.1016/j.engstruct.2013.10.030.
- [2] DENNY J W, CLUBLEY S K. Long-duration blast loading & response of steel column sections at different angles of incidence [J]. *Engineering Structures*, 2019, 178: 331–342. DOI: 10.1016/j.engstruct.2018.10.019.
- [3] JIANG Y X, ZHANG B Y, WANG L, et al. Dynamic response of polyurea coated thin steel storage tank to long duration blast loadings [J]. *Thin-Walled Structures*, 2021, 163: 107747. DOI: 10.1016/j.tws.2021.107747.
- [4] SAKURAI A. Blast wave theory [M]. Mathematics Research Center, United States Army, University of Wisconsin, 1964.
- [5] RIGBY S E, AKINTARO O I, FULLER B J, et al. Predicting the response of plates subjected to near-field explosions using an energy equivalent impulse [J]. *International Journal of Impact Engineering*, 2019, 128(1): 24–36. DOI: 10.1016/j.ijimpeng.2019.01.014.
- [6] KINGERY C N, BULMASH G. Airblast parameters from TNT spherical air burst and hemispherical surface burst [R]. US Army Armament and Development Center, Ballistic Research Laboratory, 1984.
- [7] RIGBY S E, TYAS A, FAY S D, et al. Validation of semiempirical blast pressure predictions for far field explosions: is there inherent variability in blast wave parameters? [C]//Proceedings of the 6th International Conference on Protection of Structures Against Hazards. Sheffield, 2014.
- [8] LARCHER M, CASADEI F. Explosions in complex geometries: a comparison of several approaches [J]. *International Journal of Protective Structures*, 2010, 1(2): 169–195. DOI: 10.1260/2041-4196.1.2.169.
- [9] DENNIS A A, PANNELL J J, SMYD D J, et al. Prediction of blast loading in an internal environment using artificial neural networks [J]. *International Journal of Protective Structures*, 2021, 12(3): 287–314. DOI: 10.1177/2041419620970570.
- [10] HANSEN O R, HINZE P, ENGEL D, et al. Using computational fluid dynamics (CFD) for blast wave predictions [J]. *Journal of Loss Prevention in the Process Industries*, 2010, 23(6): 885–906. DOI: 10.1016/j.jlp.2010.07.005.
- [11] REMENNIKOV A M, ROSE T A. Modelling blast loads on buildings in complex city geometries [J]. *Computers & Structures*, 2005, 83(27): 2197–2205. DOI: 10.1016/j.compstruc.2005.04.003.
- [12] SOHAIMI A S M, RISBY M S. Using computational fluid dynamics (CFD) for blast wave propagation under structure [J]. *Procedia Computer Science*, 2016, 80: 1202–1211. DOI: 10.1016/j.procs.2016.05.463.
- [13] HASTIE T, TIBSHIRANI R, FRIEDMAN J H, et al. The elements of statistical learning: data mining, inference, and prediction [M]. New York: Springer, 2009.
- [14] FLOOD I, BEWICK B T, DINAN R J, et al. Modeling blast wave propagation using artificial neural network methods [J]. *Advanced Engineering Informatics*, 2009, 23(4): 418–423. DOI: 10.1016/j.aei.2009.06.005.
- [15] REMENNIKOV A M, ROSE T A. Predicting the effectiveness of blast wall barriers using neural networks [J]. *International Journal of Impact Engineering*, 2007, 34(12): 1907–1923. DOI: 10.1016/j.ijimpeng.2006.11.003.
- [16] BEWICK B, FLOOD I, CHEN Z. A neural-network model-based engineering tool for blast wall protection of structures [J]. *International Journal of Protective Structures*, 2011, 2(2): 159–176. DOI: 10.1260/2041-4196.2.2.159.
- [17] ALSHAMMARI O G, ISAAC O S, CLARKE S D, et al. Mitigation of blast loading through blast-obstacle interaction [J]. *International Journal of Protective Structures*, 2023, 14(3): 357–389. DOI: 10.1177/20414196221115869.
- [18] PANNELL J J, RIGBY S E, PANOUTSOS G. Physics-informed regularisation procedure in neural networks: an application

- in blast protection engineering [J]. *International Journal of Protective Structures*, 2022, 13(3): 555–578. DOI: 10.1177/20414196211073501.
- [19] PANNELL J J, RIGBY S E, PANOUTSOS G. Application of transfer learning for the prediction of blast impulse [J]. *International Journal of Protective Structures*, 2023, 14(2): 242–262. DOI: 10.177/20414196221096699.
- [20] LI Q L, WANG Y, SHAO Y D, et al. A comparative study on the most effective machine learning model for blast loading prediction: from GBDT to transformer [J]. *Engineering Structures*, 2023, 276: 115310. DOI: 10.1016/j.engstruct.2022.115310.
- [21] LI Q L, WANG Y, LI L, et al. Prediction of BLEVE loads on structures using machine learning and CFD [J]. *Process Safety and Environmental Protection*, 2023, 171: 914–925. DOI: 10.1016/j.psep.2023.02.008.
- [22] HUANG Y, ZHU S J, CHEN S W. Deep learning-driven super-resolution reconstruction of two-dimensional explosion pressure fields [J]. *Journal of Building Engineering*, 2023, 78: 107620. DOI: 10.1016/j.job.2023.107620.
- [23] 孙传猛, 裴东兴, 陈嘉欣, 等. 基于深度学习的爆炸冲击波信号重构模型 [J]. *计测技术*, 2022, 42(2): 57–67. DOI: 10.11823/j.issn.1674-5795.2022.02.07.
- SUN C M, PEI D X, CHEN J X, et al. Model for reconstruction of explosion shock wave signals based on deep learning [J]. *Measurement Technology*, 2022, 42(2): 57–67. DOI: 10.11823/j.issn.1674-5795.2022.02.07.
- [24] QIU T, CHENG S, DU X Q, et al. Spacing effects on blast loading characteristics of two tandem square columns under planar shock waves [J]. *Physics of Fluids*, 2023, 35(12): 127116. DOI: 10.1063/5.0177869.
- [25] KARLOS V, LARCHER M, SOLOMOS G. Analysis of the blast wave decay coefficient in the Friedlander equation using the Kingery-Bulmash data [R]. Joint Research Center, European Commission, 2015.
- [26] ZHOU Z H. Machine learning [M]. Springer Nature, 2021. DOI: 10.1007/978-981-15-1967-3.
- [27] MISRA D. Mish: a self-regularized non-monotonic activation function[R]. *British Machine Vision Conference*, 2019. DOI: 10.48550/arXiv.1908.08681.

(责任编辑 王易难)