arXiv:2301.02580v1 [physics.geo-ph] 19 Dec 2022

Neuro-DynaStress：预测结构部件中的**动态应力**分布

Hamed Bolandi[1, 2*], Gautam Sreekumar[2], XuyangLi[1,2], Nizar Lajnef[1] 和 Vishnu Naresh Boddeti[2]

[1*]土木与环境工程，密歇根州立大学，美国密歇根州东兰辛市 Shaw Lane，邮编 48824。[2]计算机科学与工程，密歇根州立大学，美国密歇根州东兰辛市 Shaw Lane，邮编 48824。

*通讯作者。电子邮箱：bolandih@msu.edu；贡献作者：sreekum1@msu.edu；lixuyan1@msu.edu；lajnefni@msu.edu；vishnu@msu.edu；

摘要

结构部件通常会承受动态荷载，例如地震、风和爆炸。结构工程师应能够在极端灾害事件发生后或期间进行实时分析，因为此类事件需要立即采取修正措施，以避免致命失效。因此，在高度破坏性事件期间实时预测动态应力分布至关重要。目前可用的高保真方法（例如有限元模型（FEMs））本身复杂度很高，计算成本高得难以承受。因此，为了在保持精度的同时降低计算成本，本文提出了一种深度学习模型 Neuro-DynaStress。该模型基于使用偏微分方程（PDE）求解器进行的有限元模拟，预测完整的应力分布序列。模型经过设计和训练，以几何形状、边界条件和载荷序列作为输入，并预测高分辨率应力云图序列。所提出框架的性能将与使用偏微分方程求解器进行的有限元模拟结果进行比较。

关键词：深度学习；有限元分析，动态应力分布，结构工程

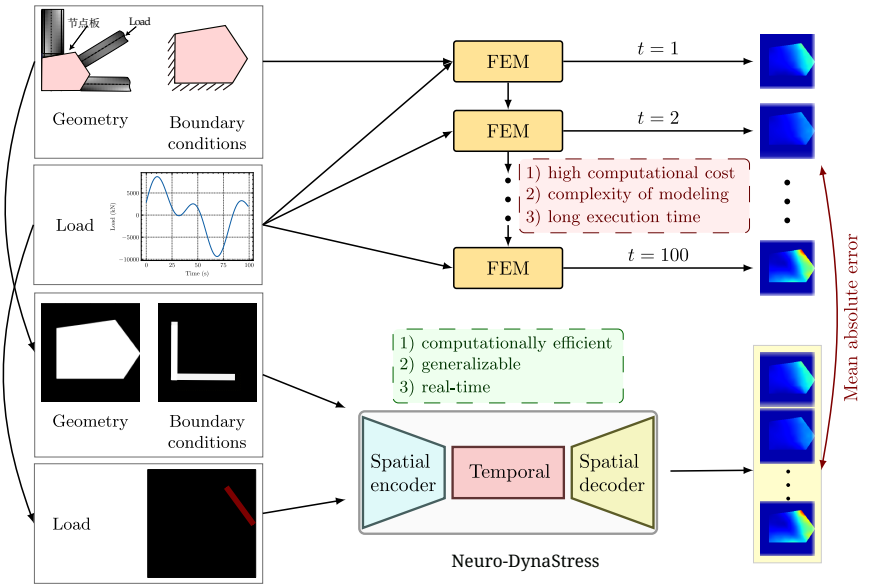

图 1：**概述：** 与有限元法不同，我们提出的 Neuro-DynaStress 计算效率高，可实现实时分析。有限元法应用的现有工作流程包括：(i) 对几何形状及其组成部分进行建模，(ii) 指定材料属性、边界条件、网格划分和载荷，(iii) 进行动态分析，其耗时可能因模型复杂度而异。Neuro-DynaStress 以几何形状、边界条件和载荷为输入，一次性预测所有时间步的动态应力分布。

1 引言

数值分析方法（例如有限元分析（FEA））通常用于对各种结构和系统进行应力分析，因为对于这些结构和系统，确定解析解并不现实或较为困难。研究人员通常使用有限元分析方法，评估航空航天、汽车、架构和土木结构系统等不同领域中各类结构的设计、安全性和维护状况。当前有限元分析应用的工作流程包括：（i）建立几何形状及其组成部件的模型；（ii）指定材料属性、边界条件、进行网格划分和加载；（iii）进行动态分析，该过程可能会因模型复杂度而耗时较长。当前有限元分析工作流程对时间的要求及其复杂性，使其难以应用于实时或近实时场景，例如灾害发生后或极端破坏性事件期间；此类事件需要立即采取修正措施，以避免灾难性失效。

基于上述有限分析（FEA）步骤，使用传统有限元分析进行完整的应力分析，计算成本很高。为了

解决这一问题，近期一些研究提出了基于深度神经网络（DNN）的方法，用于预测完好和受损结构部件中的应力分布 [1, 2],，从而无需进行静态有限元分析。但这些方法并不适用于动态有限元分析。我们提出了一种架构，可作为动态有限元分析的有限元分析求解器代理模型，同时避免相关的计算瓶颈。为展示其效用，我们对动态荷载作用下节点板中的应力分布进行建模。桥梁和建筑物高度依赖节点板，而节点板是其中最关键的部件之一。节点板的设计能够承受地震和风荷载等侧向荷载，这使得快速动态模型有助于避免灾难性失效。

这里的主要思路是训练一个模型，以便在需要实时估算时使用，例如在极端破坏性事件发生后。举例来说，针对关键结构部件，在灾害发生后或极端破坏性事件期间，需要立即进行评估，以指导纠正措施。工程师可以依靠所提出的计算高效算法，确定受损节点板上的应力分布，并采取适当的修复措施。他们需要能够快速、准确地分析节点板，而这正是我们的模型能够提供的。据我们所知，这项工作首次针对钢板这一特定领域预测动态应力分布。

2 相关工作

近期科学机器学习在数据驱动应用方面的研究涵盖了设计和拓扑优化 [3, 4], 流体动力学中的数据驱动方法 [5, 6], 分子动力学模拟 [7, 8],以及材料性能预测 [9–12]。Atalla 等人 [13] 和 Levin 等人 [14] 使用神经网络回归进行有限元分析模型更新。近来，深度学习在解决传统力学问题方面展现出潜力。一些研究人员将深度学习用于结构损伤检测，这是一种颇具前景的方法，可替代传统的结构健康监测方法 [15, 16]。

Javadi 等人 [17] 在有限元分析中使用了一种典型的神经网络，作为传统材料本构模型的代理模型。他们将几何形状简化为特征向量，这种做法难以推广到复杂案例。Oishi 等人 [18] 利用深度学习优化了有限元分析中按单元计算的单元刚度矩阵数值积分。该方法有助于加速单元刚度矩阵的计算。由于架构设计的特点，卷积神经网络（CNN）常用于涉及二维信息的任务。最近，Madani 等人 [19] 开发了一种卷积神经网络架构，用于预测动脉粥样硬化中的动脉壁应力。此外，Liang 等人 [20] 提出了一种主动脉壁应力预测卷积神经网络模型。该方法有望支持在广泛的临床应用中对人体器官进行实时应力分析。

Gulgec 等人 [21] 提出了一种卷积神经网络架构，用于对模拟的受损和完好样本进行分类，并定位钢节点板中的损伤。Modares 等人 [22] 开展了一项关于复合材料的研究，利用卷积神经网络识别结构损伤是否存在及其类型。此外，为了在不计算缺陷特征的情况下检测混凝土裂缝，Cha 等人 [23] 提出了一种基于卷积神经网络（CNN）的视觉方法。Do 等人 [24]提出了一种基于“长短期记忆”和“多层神经网络”的方法，用于预测工程结构风险评估中的裂纹扩展。Khadilkar 等人 [25]提出了一种预测非均匀三维零件所有层应力分布的方法。最近，Nie 等人 [26] 开发了一种基于卷积神经网络的方法，用于预测二维线性悬臂梁中的低分辨率应力场。Jiang 等人 [27] 开发了一种条件生成对抗网络，用于预测实体结构中的低分辨率冯·米塞斯应力分布。

已有一些研究致力于开发利用机器学习模型预测结构响应的方法。Dong 等人 [28] 提出了一种支持向量机方法，用于预测非线性结构响应。Wu 等人 [29]利用深度卷积神经网络估算结构动力响应。Zhang 等人 [31] 使用长短期记忆网络（LSTM） [30] 预测地震荷载下的非线性结构响应。Fang 等人 [32]提出了一种基于深度学习的结构健康监测（SHM）框架，该框架能够利用 LSTM 预测大坝经历爆炸后的结构动力响应。Kohar 等人 [33] 使用 3D 卷积神经网络自编码器和 LSTM，预测车辆碰撞安全性中的力-位移响应及网格变形。Schwarzer 等人 [34]构建了一种神经网络架构，将图卷积神经网络（GCN）与循环神经网络（RNN）相结合，以预测脆性材料中的裂纹扩展。Lazzara 等人 [35] 提出了一种基于双阶段长短期记忆自编码器的代理模型，用于预测飞机动态着陆响应随时间的变化。Jahanbakht 等人 [36] 提出了一种受有限元分析（FEA）启发、采用注意力变换器的深度神经网络，用于预测广阔珊瑚礁中的沉积物分布。

少数研究应力预测的模型存在预测分辨率低的问题，因此不适用于灾难性失效后的决策。据我们所知，这是首项针对钢板这一特定领域，以高精度和低延迟预测动态应力分布的研究。该算法以几何形状、边界条件和时程作为输入，并输出动态冯·米塞斯应力分布。我们将钢板建模为节点板，并在不同边施加动态荷载，同时设置不同的边界条件和多种复杂几何形状。

3 方法

3.1 数据生成

如图 2 所示，具有五条边（E1 至 E5 分别表示边 1 至 5）的二维钢板结构被视为均匀各向同性线弹性材料。通过改变各节点在水平方向和垂直方向上的位置生成不同的几何形状，如图 2 所示，由此得到 1024 个独特的五边形。所有样本的材料属性保持不变，且均为各向同性。二维钢板的几何形状接近节点板。节点板将梁和柱连接到钢结构中的支撑杆。这些构件的行为和分析至关重要，因为多份报告指出，承受侧向荷载的节点板会发生失效 [37–40]。考虑边界条件和时程荷载工况，以模拟常见节点板结构在外部荷载作用下的类似情况。实际应用中一些最常见的节点板配置如图 3 所示。

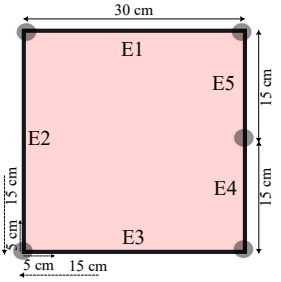

图2：用于初始化钢板几何形状的基本示意拓扑。

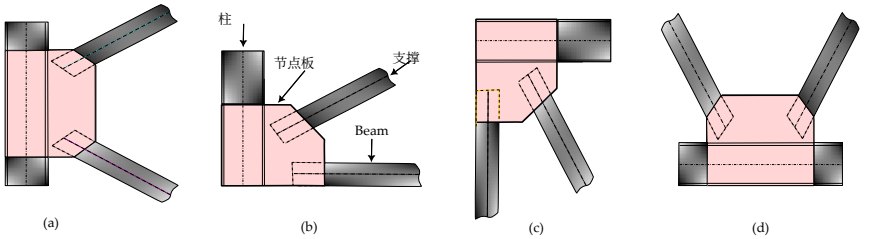

图3：工程实践中一些最常见的节点板。

通过组合 14 种随机时程荷载工况和节点板中最常见的四种边界条件，共生成了 57,344 个独特样本。边界条件如图所示。4这些边界条件模拟了实际节点板的边界条件。所有平移和转动位移

均在边界条件处固定。板的宽度和高度范围为 30 cm 至 60 cm。每个时程由 100 个时间步组成，这些时间步由随机正弦和余弦频率生成。频率范围为 1 至 3 Hz，振幅范围为 2 至 10 kN，间隔为 2 kN。水平方向和垂直方向上的所有时程如图所示。5考虑到共 100 个时间步，每个时间间隔为 0.01 秒，因此总时间为 1 秒。用于初始化种群的输入变量的所有详细信息见表1。

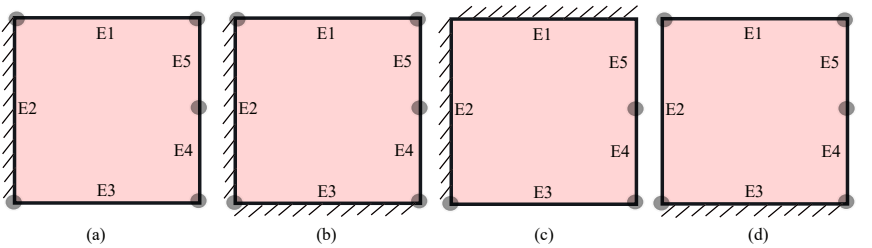

图4：用于初始化种群的不同类型边界条件 n.

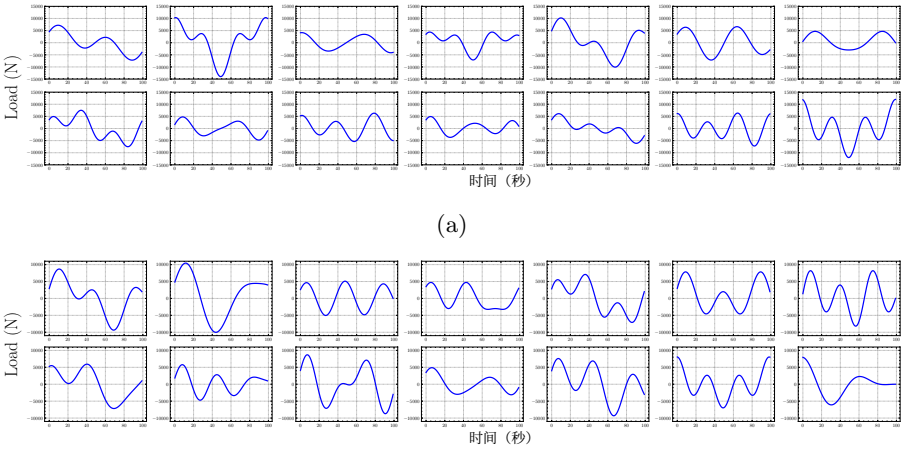

图5：时程（a）水平方向（b）垂直方向

3.2 输入数据

几何形状编码为一个 200×200 矩阵，同时也表示为一幅二值图像。其中，0（黑色）和1（白色）分别表示几何形状的外部和内部，如

表 1：输入变量

几何形状	边界条件	Load 位置	频率 (HZ)	Load (kN)	Time 步数	总时间（秒）
五边形	E2	E4E5	1,1.5,2,2.5,3	2,4,6,8,10	100	1
五边形	E2E3	E5	1,1.5,2,2.5,3	2,4,6,8,10	100	1
五边形	E1E2	E4	1,1.5,2,2.5,3	2,4,6,8,10	100	1
五边形	E3	E2E5	1,1.5,2,2.5,3	2,4,6,8,10	100	1

图 6（a）所示。边界条件也通过另一幅200 × 200 像素二值图像表示，其中受约束边由1（白色）定义，如图 6（b）所示。此外，水平方向和垂直方向时程的每个时间步均编码在相应帧的载荷位置中。每个时间步的载荷位置取值介于0和1之间，分别对应时程中的各个时间步，其余所有单元均为零。每个样本在水平方向和垂直方向上的所有载荷帧均保存为维度为 $100 \times 200 \times 200$ 的张量。图 6（c）和6（d）展示了水平方向和垂直方向上的载荷。图 6（c）和6（d）中的彩色载荷位置仅用于可视化。图 6 的每一行代表一个模拟样本。边界条件及其载荷位置的详细信息见表 1。

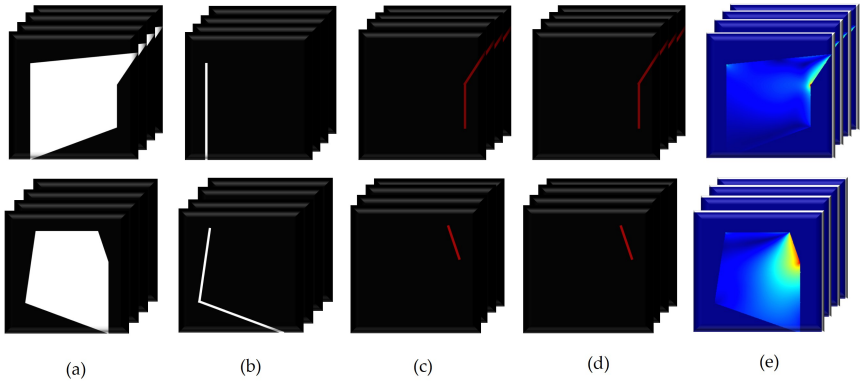

图 6：应力分布预测的输入与输出表示：(a) 几何形状，(b) 边界条件，(c) 水平载荷，(d) 垂直载荷，(e) 输出

3.3 输出数据

我们使用 MATLAB 工具箱中的偏微分方程（PDE）求解器进行有限元分析，以获得每个样本的应力分布。我们使用 MATLAB PDE 求解器的瞬态平面应力函数生成

动态应力云图，作为模型的真实值。我们将几何形状、边界条件、材料属性和时程定义为输入，偏微分方程求解器则返回与输入对应的应力分布序列。MATLAB 偏微分方程工具箱的网格生成器只能生成与卷积神经网络不兼容的非结构化三角网格。三角网格单元的最小和最大尺寸分别为 5 毫米和 10 毫米。由于图像中的每个像素都应表示一个单元，我们开发了 200×200一个网格表面，其尺寸与最大可能几何形状的尺寸相同。图 7 (a) 和 7 (b) 展示了随机样本上的非结构化网格和 200×200 网格表面。随后，对三角单元与网格之间的应力值进行插值，以确定与卷积神经网络兼容的应力分布。材料几何形状之外所有单元的应力值均设为零，如图 6 (e) 所示。

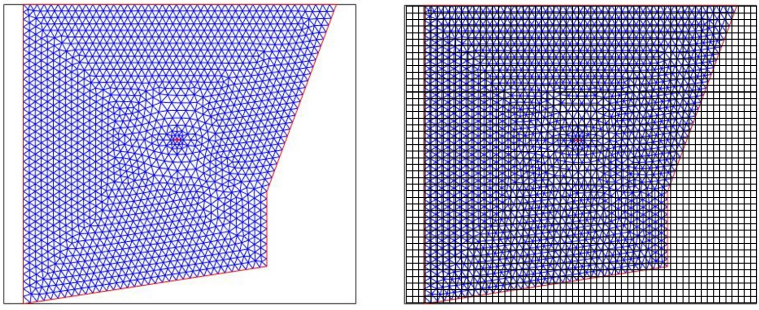

图 7：网格生成示例：(a) 非结构化三角网格，(b) 结构化网格表面

最大样本的尺寸为 600×600 毫米，最小样本的尺寸为 300×300 毫米。在样本上使用 200×200 的网格，使每个单元的尺寸为 3×3 毫米，这意味着每帧输出包含 40000 个像素。这个高分辨率数据集带来了显著的精度提升。整个数据集中各单元冯·米塞斯应力值的最大值和最小值分别为 279,370 兆帕和 -980 兆帕。我们将所有输出数据归一化到 0 到 1 之间，以确保更快收敛，并将其编码为每帧 200×200。

3.4 应力计算

有限元分析工作流程的第 (iii) 阶段包括线性有限元分析的应力计算，其步骤如下，详见引言部分：

$$KQ = F \tag{1}$$

其中， K 表示全局刚度矩阵， F 表示施加到各节点的载荷向量， Q 表示位移。刚度矩阵 K 由各单元的刚度矩阵 K_e组成：

$$K_e = A_e B^T D B \tag{2}$$

其中， B 表示应变-位移矩阵； D 表示应力-应变矩阵； A_e 表示单元面积。网格几何形状和材料属性决定了 B 和 D。随后，将局部刚度矩阵 k_e 添加到全局刚度矩阵中。位移边界条件通过全局刚度矩阵 K中的相应行和列进行编码。求解 Q 可采用直接分解或迭代方法。

根据方程计算全局位移1后，我们可以计算节点位移 q ，然后计算每个单元的应力张量，如下所示：

$$\sigma = DBq \tag{3}$$

其中， σ 表示一个单元的张量。随后，使用二维冯·米塞斯应力准则计算每个单元的冯·米塞斯应力：

$$\sigma_{v_m} = \sqrt{\sigma_x^2 + \sigma_y^2 - \sigma_x \sigma_y + 3\tau_{x_y}^2} \tag{4}$$

其中，σ_{v_m} 表示冯·米塞斯应力， σ_x和 σ_y 为正应力分量，τ_{x_y} 为剪应力分量。

4 提出的方法

我们使用卷积层对输入中的空间信息进行编码。我们假设，这些层能够融合几何形状、边界条件和载荷中的信息。动态结构系统的一个关键特征是其状态具有时间依赖性。长短期记忆网络（LSTM）适用于对序列中的时间信息进行建模，因此在我们的实验中，它是用于模拟结构动态系统的理想选择。为获得高质量的二维重建结果，我们在解码器中使用转置卷积层。为进一步提升训练效果和性能，我们采用了近期提出的特征对齐金字塔网络（FaPN） [41]中的模块。FaPN使解码器能够直接访问来自编码器的信息。总体而言，我们的网络架构由四个模块组成：由卷积层构成的编码器、由长短期记忆网络模块构成的时间模块、由转置卷积层构成的解码器，以及用于连接编码器和解码器的对齐模块。各模块中的层数以及长短期记忆网络模块的层数，是根据其性能确定的。

该架构的示意图见图8。网络中使用的层尺寸和超参数汇总于表2。

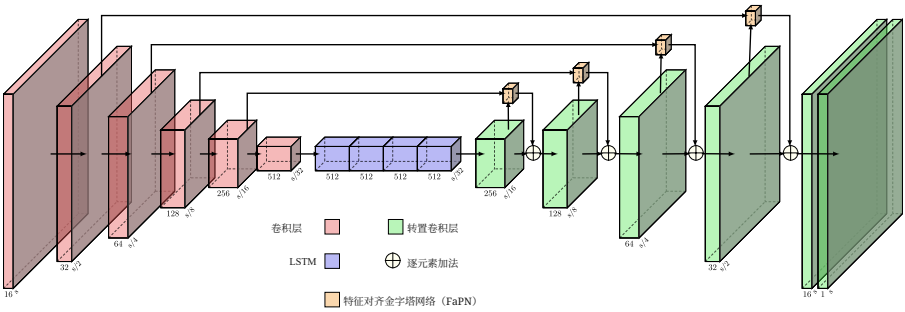

图 8：所提出的 Neuro-DynaStress 架构。卷积编码器将原始输入数据映射到潜在空间。长短期记忆网络层处理跨不同时间帧的信息。最终输出通过转置卷积层从得到的潜在表示中生成。

表 2：网络层和超参数

层类型	层数	第一层 (H×W×C)	最后一层 (H×W×C)
Conv	6	200×200×16	7×7×512
LSTM	4	1×1×512	1×1×512
转置卷积	5	13×13×256	200×200×16
FaPN	4	13×13×256	100×100×32
批量大小	学习率	权重衰减	损失函数
8	10^{-4}	10^{-5}	MAE

5 损失函数和性能指标

我们使用式5 中定义的平均绝对误差（MAE）作为主要训练损失和评估指标。为确保模型不会对单一指标过拟合，我们还使用平均相对百分比误差（MRPE）来评估预测应力分布的整体质量。

$$\mathrm{MAE} = \frac{1}{NT}\sum_{N,T}^{n,t}|S(n,t) - \hat{S}(n,t)| \tag{5}$$

$$\mathrm{MRPE} = \frac{\mathrm{MAE}}{\max|S(n,t), \hat{S}(n,t)|} \times 100 \tag{6}$$

其中， $S(n,t)$ 是时间步 t 时节点 n 处的真实应力值，由 ˆFEA 计算得出； $S(n,t)$ 是模型预测的对应应力值； N 是样本每一帧中的网格节点总数， T 是每个样本中的时间步总数。如前所述，我们在实验中设定了 $T = 100$ 。

6 实现与计算性能

我们使用 PyTorch [42] 和 PyTorch Lightning 实现了模型。我们采用 AdamW优化器 [43] 作为优化器，学习率为 10^{-4}。我们发现，批量大小为 8 时效果最佳。我们在 AMD EPYC 7313 16 核处理器和两块 NVIDIA A6000 48G GPU 上评估了模型的计算性能。训练阶段，单个包含 100 帧的样本在批量大小为 8 时耗时 10 秒。训练阶段包含一次前向传播和反向传播。单个样本的推理时间不到 5 毫秒，可满足实时性要求。最强大的有限元求解器解决相同问题需要 10 分钟到 1 小时。因此，Neuro-DynaStress 的速度约为传统有限元求解器的72×10^4 倍。我们将有限元求解器对单个样本进行几何建模、网格划分和分析等所有流程所需的最短时间估算为约 10 分钟。MATLAB PDE 求解器不使用 GPU加速。这表明，我们提出的方法在验证阶段能够满足实时性要求。

7 结果与讨论

7.1 定量评估

我们的模型在训练数据集上训练了 45 个训练轮次，并使用单独的指标在验证数据集上进行评估。训练数据集包含 48,755 个样本，验证数据集包含 8,589 个样本，两者共同构成整个数据集的 80%-20% 划分。模型根据之前的五帧输入序列预测五帧输出，直至预测完全部 100 帧。在验证期间，以五帧为一个序列时获得了最佳验证性能。验证期间的最佳检查点（第 40 个训练轮次）是所有误差指标的依据。验证数据集的平均相对百分比误差仅为 2.3%。

7.2 定性评估

图中展示了从验证数据集中随机选取的几个样本的预测结果。9a 和9b。第一行表示一个参考样本的 100 帧中的 5 帧。第二行展示了与第一行帧对应的预测值，最后一行表示相应预测值中的误差。这些柱分别表示时间步 1、25、50、75 和 100 秒。我们以固定间隔可视化帧

每隔 25 秒展示一次，以评估不同范围的动态应力预测。

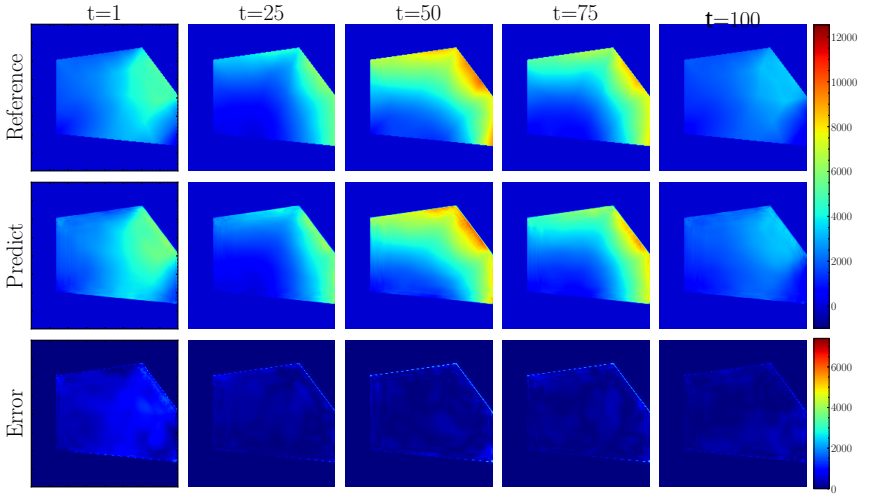

(a)

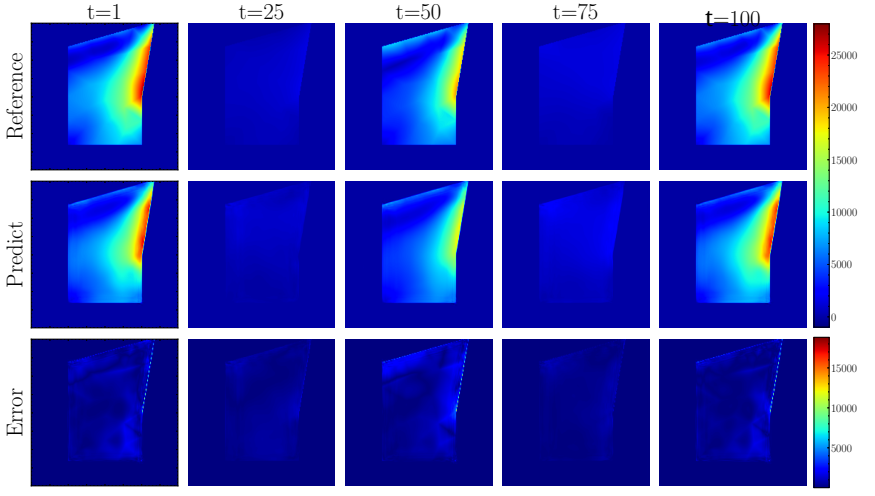

(b)

图9：两个样本在不同时间序列中的动态应力分布预测结果及相应误差。顶行对应参考帧，中间行显示预测值。底行显示对应帧之间的绝对误差（单位：= 兆帕）

为了便于可视化，图 9a 和9b 中的参考值和预测值均使用各样本的最大值和最小值缩放到相同范围。误差则单独缩放。如图 9a所示，预测帧与对应的参考帧非常相似。尽管几何形状包含尖角和边，而这些区域对于卷积神经网络来说难以重建，但我们的模型仍能够对其进行预测。除第一帧的一小部分外，误差均处于可接受范围内，这表明了我们模型的预测精度。图9b展示了另一次成功的重建。将参考值与对应的预测帧进行比较可以看出，我们的 Neuro-DynaStress 模型能够同时捕捉载荷变化和最大应力值。此外，这些结果表明，我们的模型能够预测应力分布变化幅度较大的动态应力分布。

图10展示了一个随机失效样本。尽管模型成功预测了帧中的大部分区域，但它无法重建90度角处的高应力集中。由于卷积神经网络通常难以处理锐利的边缘，因此在数据预处理过程中使用高斯滤波器平滑尖角，可能有助于网络更好地训练。此外，由于帧 $t = 25$ 和 $t = 75$ 中的载荷低于其他帧，因此这些帧中的预测是可以接受的。

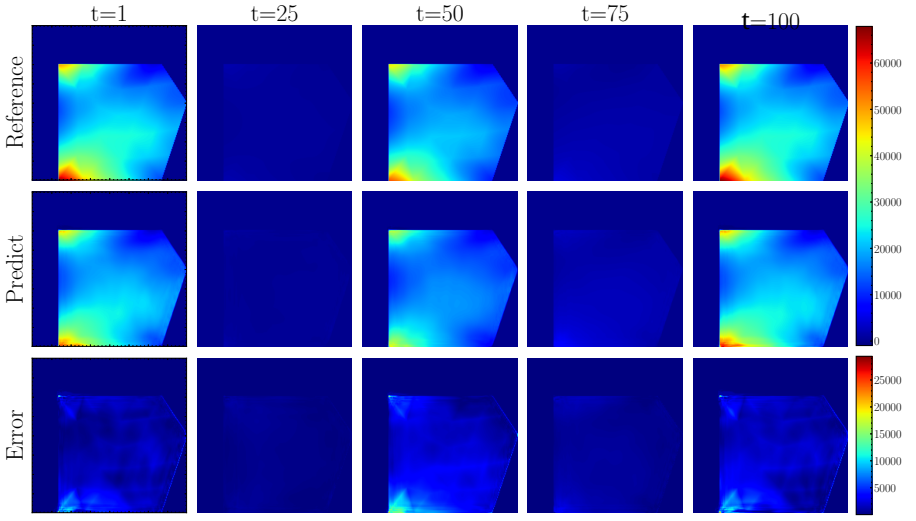

图 10：不同时间序列中预测失败的动态应力分布及其对应的误差。（单位：$=$ 兆帕）

预测值在时间上保持一致也很重要。为了定性展示所提出方法的时间一致性，图 11a 展示了

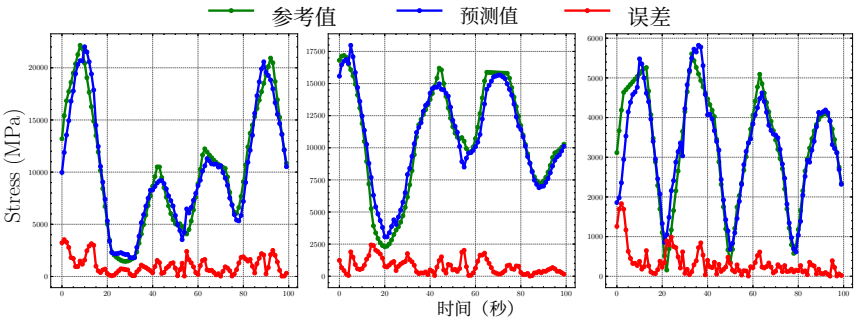

(a)

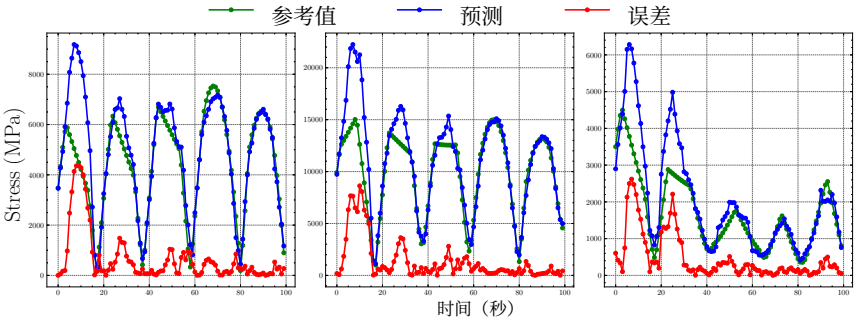

(b)

图11：随机选取的一个单元中，100 帧预测值、参考值和误差的应力值对比。(a) 预测成功 (b) 预测失败（单位： = MPa-T）。

随机选取的一个单元中成功预测的 100 帧应力值对比。如图所示，在大多数时间序列中，参考值与预测分布几乎完全相同，误差接近于零，尽管应力随时间大幅变化。图 11a 说明，在峰值点的时间平滑性较高时，预测值与参考值的吻合程度更高。例如，图 11a最右侧的图中，最后一个峰值处的应力变化呈平滑的高斯分布，预测值与参考值吻合良好。然而，在其余图中，尽管大多数峰值处的应力值缺乏平滑性，预测值仍与参考值具有良好的相关性。此外，根据图 11a，我们可以得出结论：与峰值相比，该模型对谷值应力的预测效果更好。

我们还在图 11b 中展示了一些预测失败的案例，以说明所提出模型的局限性。从所有非高斯应力分布图中可以看出，该模型难以准确捕捉峰值应力。然而，在

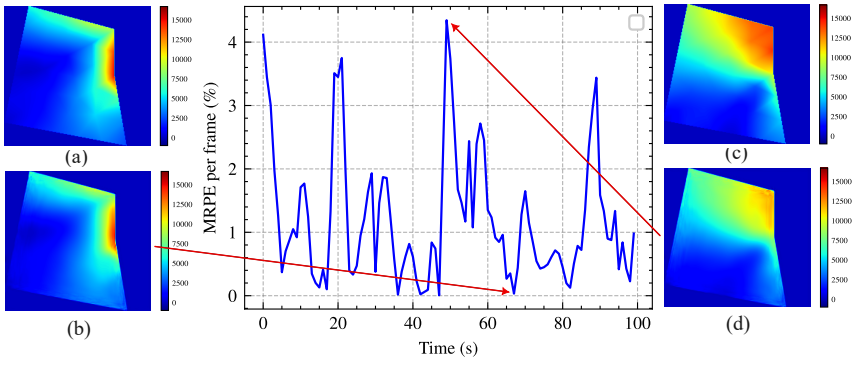

(a)

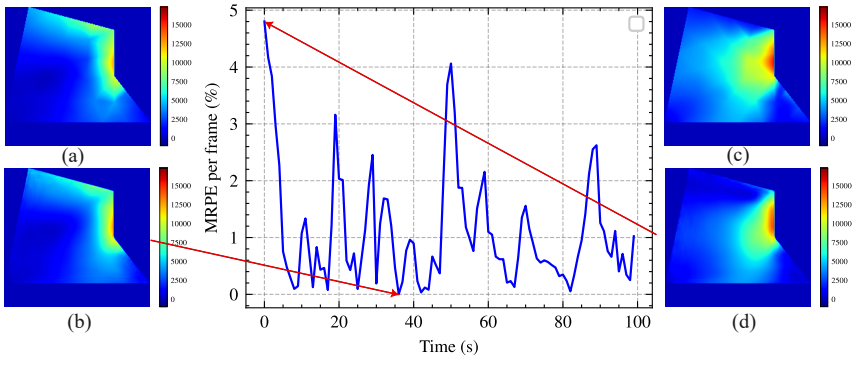

(b)

图 12：随机选取样本中 100 帧的相对误差。中间的图表示每帧的平均相对百分比误差（MRPE）。每幅图中的 (a) 和 (c) 表示参考值；(b) 和 (d) 表示对应的预测值。箭头表示所示帧的平均相对百分比误差。（单位： = MPa-T）。

图 11b左侧的前两幅图中，由于参考值中的应力值在这些位置呈高斯分布，因此预测值与参考值的后续峰值完全吻合。图 12a 和 12b 展示了随机选取的样本在 100 帧中的平均相对百分比误差（MRPE），以及对应于最小和最大 MRPE 的帧。从两个样本都可以看出，最小误差接近零，只有少数帧的误差超过 2%。

7.3 消融研究

该架构的高效性归功于我们所做的几项设计选择。我们的架构对时间帧之间的时间依赖关系，以及输入中不同单元之间的关系进行建模。即使

自注意力在序列建模中展现了最先进的性能，但并不适用于缺乏大量数据的任务。因此，我们使用长短期记忆网络进行序列建模。为了验证这一观点，我们将该架构与其他基线架构进行比较。我们与表 3 中所示的三种架构进行比较。采用多头自注意力的模型与我们的架构非常相似，不同之处在于，我们模型中的长短期记忆网络模块被自注意力模块取代。其他模型的详情见表 3。我们将该架构称为 Neuro-DynaStress。结果见表3，最佳结果以粗体标出。

表3：架构比较

	用于建模时间信息的架构			
	多头自注意力	LSTM	LSTM	LSTM
FaPN	✓	✓	✓	×
跳跃连接	✓	✓	×	×
平均相对百分比误差(%)	4.5	**2.3**	6.6	9.7

8 结论

我们提出了 Neuro-DynaStress 模型，该模型结合了卷积神经网络（CNN）和长短期记忆网络（LSTM），用于预测完整的动态应力分布序列。该模型旨在通过几何形状、边界条件和载荷序列作为输入进行训练，并预测高分辨率动态应力等值线序列。卷积组件用于提取空间特征，而 LSTM 则捕捉帧间的时间依赖关系。我们使用特征对齐模块来提升模型的训练效果和性能。该模型使用 MATLAB 中偏微分方程工具箱生成的合成数据进行训练。
Neuro-DynaStress 能够预测动态应力分布，平均相对百分比误差为 2.3%；这一误差率在工程领域被认为可以接受。

声明

- 本研究部分由美国国家科学基金会资助，资助项目编号为 CNS 1645783。

- 本文作者之间不存在利益冲突
- 当前研究期间生成和/或分析的数据集，可应合理请求向通讯作者获取。

参考文献

[1] Bolandi, H., Li, X., Salem, T., Boddeti, V., Lajnef, N.：连接有限元与深度学习：结构部件中的高分辨率应力分布预测。《结构与土木工程前沿》（2022年）[2] Bolandi, H., Li, X., Salem, T., Boddeti, V.N., Lajnef, N.：用于预测含应力集中的受损结构部件应力分布的深度学习范式。《工程软件进展》**173**，103240（2022年）[3] Umetani, N.：利用自编码器网络探索生成式三维形状。载于：SIGGRAPH Asia 2017 技术简报，第1–4页（2017年）[4]Yu, Y., Hur, T., Jung, J., Jang, I.G.：无需迭代即可确定近似最优拓扑设计的深度学习。《结构与多学科优化》**59(3)**，787–799（2019年）[5] Farimani, A.B., Gomes, J., Pande, V.S.：通过深度学习研究传输现象的物理规律。arXiv 预印本 arXiv:1709.02432（2017年）[6] Kim, B., Azevedo, V.C., Thuerey, N., Kim, T., Gross, M., Solenthaler, B.：深度流体：用于参数化流体模拟的生成网络。载于：《计算机图形论坛》，第38卷，第59–70页（2019年）。Wiley 在线图书馆[7] Goh, G.B., Hodas, N.O., Vishnu, A.：计算化学中的深度学习。《计算化学杂志》**38(16)**，1291–1307（2017年）[8] Mardt, A., Pasquali, L., Wu, H., No´e, F.：用于分子动力学深度学习的 VAMPnets。《自然·通讯》**9(1)**，1–11（2018年）[9] Mohammadi Bayazidi, A., Wang, G.-G., Bolandi, H., Alavi, A.H., Gandomi, A.H.：利用多基因遗传编程估算混凝土弹性模量。《工程数学问题》**2014年**（2014年）

[10] Sarveghadi, M., Gandomi, A.H., Bolandi, H., Alavi, A.H.：采用机器学习方法开发钢纤维增强混凝土梁抗剪强度预测模型。《神经计算与应用》**31(7)**, 2085–2094 (2019年)

[11] Mousavi, S.M., Aminian,P., Gandomi, A.H., Alavi, A.H., Bolandi, H.：采用基因表达式编程建立高性能混凝土抗压强度新预测模型。《工程软件进展》**45(1)**, 105–114 (2012年)

[12] Bolandi, H., Banzhaf, W., Lajnef, N., Barri, K., Alavi, A.H.：一种用于预测混凝土中纤维增强聚合物筋粘结强度的智能模型：一种软

计算方法。《Technologies》**7**(2), 42（2019年）[13] Atalla, M.J., Inman, D.J.：关于使用神经网络进行模型更新。《机械系统与信号处理》**12**(1), 135–161（1998）[14] Levin, R.I., Lieven, N.：使用神经网络进行动态有限元模型更新。《声学与振动杂志》**210**(5), 593–607（1998）[15] Fan, Z., Wu, Y., Lu, J., Li, W.：基于卷积神经网络结构化预测的路面裂缝自动检测。arXiv 预印本 arXiv:1802.02208（2018年）[16] Dung, C.V.,等：使用深度全卷积神经网络自主检测混凝土裂缝。《Automation in Construction》**99**, 52–58（2019年）[17] Javadi, A., Tan, T., Zhang, M.：用于有限元分析中本构建模的神经网络。《Computer Assisted Mechanics and Engineering Sciences》**10**(4), 523–530（2003年）[18] Oishi, A., Yagawa, G.：深度学习增强的计算力学。《计算机在应用力学与工程中的方法》**327**, 327–351（2017年）[19] Madani, A., Bakhaty, A., Ki m, J., Mubarak, Y., Mofrad, M.R.：衔接有限元与机器学习建模：动脉粥样硬化中动脉壁的应力预测。《Journal of biomechanical engineering》**141**(8)（2019年）[20] Liang, L., Liu, M., Martin, C., Sun, W.：一种估算应力分布的深度学习方法：有限元分析的快速精准代理模型。《Journal of The Royal Society Interface》**15**(138), 20170844（2018年）[21]Gulgec, N.S., Tak´a˘c, M., Pakzad, S.N.：用于稳健结构损伤检测与定位的卷积神经网络方法。《Journal of computing in civil engineering》**33**(3), 04019005（2019年）[22] Modarres, C., Astorga, N., Droguett, E.L., Meruane, V.：用于自动损伤识别和损伤类型识别的卷积神经网络。《Structural Control and Health Monitoring》**25**(10), 2230（2018年）[23] Cha, Y.-J., Choi, W., B¨uy¨uk¨ozt¨urk, O.：基于深度学习、使用卷积神经网络进行裂缝损伤检测。《Computer-Aided Civil and Infrastructure Engineering》**32**(5), 361–378（2017年）

[24] Do, D.T., Lee, J., Nguyen-Xuan, H.：快速评估裂缝扩展路径

使用时间序列预测。《工程断裂力学》**218**, 106567 (2019年)[25] Khadilkar, A., Wang, J., Rai, R.：基于深度学习的自下而上SLA 3D打印工艺应力预测。《国际先进制造技术杂志》**102**(5), 2555–2569 (2019年)[26] Nie, Z., Jiang, H., Kara, L.B.：使用卷积神经网络预测悬臂结构中的应力场。《工程计算与信息科学杂志》**20**(1), 011002 (2020年)[27]Jiang, H., Nie, Z., Yeo, R., Farimani, A.B., Kara, L.B.：StressGAN：一种用于二维应力分布预测的生成式深度学习模型。《应用力学杂志》**88**(5) (2021)[28] Yinfeng, D., Yingmin, L., Ming, L., Mingkui, X.：基于支持向量机的非线性结构响应预测。《声学与振动杂志》**311**(3-5), 886–897 (2008)[29]Wu, R.-T., Jahanshahi, M.R.：用于结构动力响应估计和系统辨识的深度卷积神经网络。《工程力学杂志》**145**(1), 04018125 (2019年)[30] Hochreiter, S., Schmidhuber, J.：长短期记忆。《神经网络》**9**(8), 1735–1780 (1997)[31]Zhang, R., Chen, Z., Chen, S., Zheng, J., B¨uy¨uk¨ozt¨urk, O., Sun, H.：用于非线性结构地震响应预测的深度长短期记忆网络。《计算机与结构》**220**, 55–68 (2019年)[32] Fang, X., Li, H., Zhang, S.-r., Wang, X.-h., Wang, C., Luo, X.-c.：结合有限元与深度学习网络，预测爆炸荷载作用下混凝土重力坝的结构动力响应。《国防技术》(2022)[33] Kohar, C.P., Greve, L., Eller, T.K., Connolly, D.S., Inal, K.：一种利用CAE仿真加速设计过程的机器学习框架：在结构碰撞耐撞性有限元分析中的应用。《计算机在应用力学与工程中的方法》**385**, 114008 (2021)[34] Schwarzer, M., Rogan, B., Ruan, Y., Song, Z., Lee, D.Y., Percus, A.G., Chau, V.T., Moore, B.A., Rougier, E., Viswanathan, H.S., 等：学习失效：使用循环图卷积神经网络预测脆性材料模型中的断裂演化。《计算材料科学》**162**, 322–332 (2019年)

[35]Lazzara, M., Chevalier, M., Colombo, M., Garcia, J.G., Lapeyre, C., Teste, O.：基于LSTM自编码器降维方法的飞机动态着陆载荷仿真代理建模。《航空航天科学与技术》**126**，107629（2022年）[36] Jahanbakht, M., Xiang, W., Azghadi, M.R.：使用视觉Transformer与有限元分析预测大堡礁沉积物。《神经网络》**152**，311–321（2022年）[37] ZAHRAEI, S.M., Heidarzadeh, M.：2003年巴姆地震对结构造成的破坏性影响（2007）[38] Zahrai, S.M., Bolandi, H.：中心支撑框架意外偏心连接的侧向性能研究：一种有限元建模方法。《KSCE土木工程杂志》**18(5)**，1421–1428（2014年）[39]Zahrai, S., Bolandi, H.：面外偏心对中心支撑框架侧向行为影响的数值研究。《国际钢结构杂志》**19(2)**，341–350（2019年）[40] BOLANDI, H., ZAHRAI, S.：支撑构件与柱和梁连接处的面内偏心对钢框架性能的影响（2013）[41]Huang, S., Lu, Z., Cheng, R., He, C.：FaPN：用于密集图像预测的特征对齐金字塔网络。载于：IEEE/CVF国际计算机视觉会议论文集，第864–873页（2021）[42] Paszke, A., Gross, S., Massa, F., Lerer, A., Bradbury, J., Chanan, G., Killeen, T., Lin,Z., Gimelshein, N., Antiga, L., 等：PyTorch：一种命令式风格、高性能的深度学习库。《神经信息处理系统进展》**32** （2019年）[43] Loshchilov, I., Hutter, F.：解耦权重衰减正则化。arXiv预印本 arXiv:1711.05101（2017年）