

· 研究进展 ·

土木工程智能防灾减灾研究进展

纪军¹ 李惠^{2*}

1. 国家自然科学基金委员会 工程与材料科学部, 北京 100085
2. 哈尔滨工业大学 土木工程学院, 哈尔滨 150090

[摘要] 本文基于国家自然科学基金创新研究群体项目“城市工程结构抗灾韧性与智能防灾减灾”(编号:51921006)和重大研究计划集成项目“高雷诺数湍流数据库的构建及湍流机器学习集成研究”(编号:92152301)的研究,从土木工程防灾减灾学科背景和现状、灾害控制方程物理机器学习求解理论、智能风工程、智能地震工程和防灾减灾智能设计等方面介绍国内外土木工程智能防灾减灾理论体系的研究进展,并对其未来学术发展方向做了探讨和展望。

[关键词] 土木工程智能防灾;机器学习;智能风工程;智能地震工程

土木工程灾害主要包括风、地震、火灾和爆炸等,其中风灾和地震具有极端性和复杂性特征,是土木工程防灾减灾领域研究最深入、最系统的两类灾害,并分别形成了风工程和地震工程两个学科分支。因此,本文主要讨论这两类灾害。传统风工程和地震工程理论是以物理力学为基础建立的,其科学逻辑是灾害作用→结构物理力学模型→结构灾害响应。但随着高层建筑、大跨空间建筑和大型桥梁等工程复杂度愈来愈高,传统物理力学灾害模拟的准确性和计算效率都变得极具挑战;另一方面,历经百年发展的土木工程风灾和地震灾害积累了大量数据,当前人工智能装备与系统(包括无人机、机器人、群智感知装备、计算机视觉、边缘计算等)也极大促进土木工程高密度灾害数据的感知和采集。基于机器学习高维非线性函数逼近能力的科学原理,并融合土木工程物理定理、规律与控制方程,挖掘并揭示土木工程大数据蕴含的灾害高维行为及其物理机制和规律,建立作用至结构响应映射的物理机器学习模型,研究大规模城市工程系统灾害行为智能计算方法和灾害物理—数据(实—虚交互)管理技术,发展土木工程防灾减灾智能设计方法,开创人工智能与土木工程防灾减灾融合的研究范式和理论体系,深刻变革土木工程防灾减灾科学与技术。



李惠 哈尔滨工业大学教授,国家自然科学基金创新研究群体项目负责人、国家杰出青年科学基金获得者,现任中国振动工程学会副理事长。在 *Science*、*Nature* 等学术期刊发表论文近 200 篇,曾获国家科技进步奖二等奖 4 项、美国 ASCE G W Housner 奖章和 R H Scanlan 奖章。



纪军 博士,研究员,国家自然科学基金委员会工程与材料科学部工程四处处长。

1 学科背景与现状

1940 年美国 Tacoma 大桥风毁拉开了现代风工程研究的序幕,自此结构抗风设计不仅考虑静风效应还要考虑风致振动,风振包括颤振、抖振、涡振、尾流驰振、风雨振等,历经 80 余年发展,至今已形成系统的风工程理论。这些理论以结构动力学为核心,主要研究建立半经验半理论气动力模型。虽然风工程理论在实践中取得巨大成功,但还存在一些重要挑战:

(1) 随着土木工程结构复杂度提高,低维空间半经验半理论气动力模型和结构力学模型准确性和普适性面临巨大挑战,且气动力模型参数需要大量风洞试验标定确定。充分利用 80 余年风工程积累的大数据,基于机器学习高维空间非线性函数逼近能力,并融合传统风工程理论,建立基于大数据的气动力和结构力学物理机器学习模型,研究基于大数据的风场与结构风振映射关系物理机器学习求解方法,将传统风工程变革为大数据机器学习范式的风工程^[1-3]。

(2) 结构风振是流固耦合问题,涉及流体微分控制方程和动力学微分控制方程,传统风工程主要以结构动力学为核心,对流体动力学和涡动力学研究很少,严重制约对结构风振机理深刻认识、结构气动力模型精确建模、以及结构气动外形与流动控制技术创新。基于机器学习高维空间非线性函数逼近能力和灵活网络架构,微分方程机器学习求解范式已经成为应用数学和流体力学领域研究热点^[4,5],微分方程求解精度与效率有望取得突破性进展^[6],它不仅变革微分方程求解范式,也为传统风工程拓展至流体动力学和结构动力学双核心提供契机。

地震工程起源于 20 世纪 20 年代末,地震工程学科体系涵盖工程地震、结构地震响应分析理论、结构抗震试验技术、结构抗震设计方法、震后评估与恢复重建决策理论等。历经百年发展,地震工程科学理论和技术已相对成熟。地震工程领域长期存在计算不准确难题,当前还面临大规模城市地震动场和工程系统计算效率以及震后大规模城市工程系统地震破坏评估效率低和主观性等挑战,机器学习和人工智能为解决这些挑战提供了新的学术思路:

(1) 充分利用百年科学研究和历次地震灾害积累的大数据,建立基于大数据的输入输出映射关系的物理机器学习模型,研究土木工程非线性地震响应、大规模地震动场和大规模城市工程系统地震破坏、震后大规模城市工程系统地震破坏与损失的高效高精度物理机器学习求解方法,将传统基于物理

力学的地震工程变革为基于大数据机器学习范式的工程。

(2) 与风工程相似,地震工程波动微分控制方程和动力学微分控制方程物理机器学习求解范式也将变革传统地震工程控制方程的数值计算范式。

风工程与地震工程物理机器学习求解理论的本质是高维空间非线性函数隐式或显式地逼近控制方程与模型的解,其求解统一网络架构如图 1 所示,隐式求解是基于大数据建立输入输出映射关系的数据模型,显式求解无需大数据直接以满足控制方程及其初边值条件为约束进行求解。具体求解方式分为三类:

(1) 机器学习显式求解微分方程,输入是求解问题的时空坐标和灾害作用/源项,输出是方程的解,以方程平衡条件和初边值条件为损失函数,损失函数最小使输出等于方程的解。

(2) 机器学习显式或隐式替代传统计算流体力学或动力学或波动方程数值计算的某些模块,以提高计算精度或计算效率,称之为数值计算—机器学习混合方法。

(3) 物理增强微分方程数据求解方法,通过大数据并融合物理性质建立输入输出映射的机器学习模型,该模型隐式地以高维函数逼近微分方程的解(或解的部分性质)与模型,因而可以推广至数据未涵盖的参数区间、初边值条件和荷载等,以及将低可信低质量数据同化为高可信高质量数据,因通过前向简单数学运算直接预测方程的解或模型输入输出映射关系使得该方法计算效率较高,广泛应用于建模预测和数据同化。

与计算机领域不同,土木工程遵循相关的物理定理和规律及控制方程,机器学习融合土木工程物理性质,可约束解空间,极大提高机器学习计算精度、计算效率、计算规模、泛化能力与鲁棒性。

由于(1)和(2)均直接涉及微分控制方程的求解,是风工程和地震工程共性基础问题;(3)通过挖掘数据特征隐式逼近微分控制方程的解(或解的某些性质)和模型。因此,本文首先介绍基于(1)和(2)

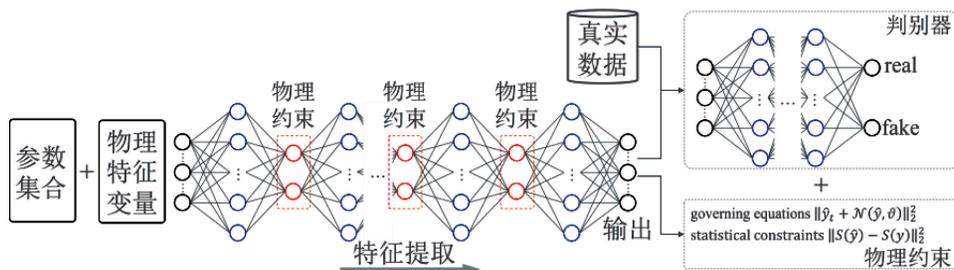


图 1 土木工程智能防灾减灾物理机器学习求解范式统一网络架构

范式的土木工程灾害控制方程物理机器学习显式和混合求解方法;其次介绍基于(3)范式的智能风工程、智能地震工程研究进展;最后介绍土木工程防灾减灾智能设计方法相关进展。

2 土木工程灾害控制方程物理机器学习显式和混合求解方法

风工程和地震工程控制方程包括流体力学微分方程(Navier-Stokes 方程,简称 N-S 方程)、动力学微分方程和波动微分方程。本文介绍几类微分方程物理机器学习显式和混合求解方法。

2.1 微分方程物理机器学习显式求解方法

微分方程物理机器学习显式求解的原理是神经网络通用近似定理可逼近微分方程时空解,分为网络时空表征求解方法与参数化非线性偏微分方程算子学习求解方法。

网络时空表征求解方法可获取微分方程的强解或弱解。求解微分方程强解的代表性网络为物理融合神经网络(Physics-informed Neural Networks, PINNs)^[7];神经网络输入为微分方程求解域时空坐标、输出是方程的解,损失函数为微分方程残差和初

边值条件,训练网络使损失函数收敛至最小值即获得微分方程的解。Jin 等^[8]在 PINNs 框架下设计了求解 N-S 方程的 NSFnets,其架构如图 2 所示,图中 $\mathbf{u}=[u, v, w]^T$ 为无量纲速度, t 为无量纲时间, p 为无量纲压力, $Re=UD/\nu$ 为特征速度 U 、特征尺度 D 与运动粘性系数 ν 定义的雷诺数。NSFnets 将流速 $\mathbf{u}=[u, v, w]^T$ 与压力 p 表征为时空函数 $(t, x, y, z) \mapsto (u, v, w, p)$, 损失函数约束网络输出 (u, v, w, p) 满足 N-S 方程及初边值条件,

$$L = L_e + \alpha L_B + \beta L_I, \quad \hat{\alpha}^{(k+1)} = \frac{|\nabla_{\theta} L_e|}{|\nabla_{\theta} L_B|},$$

$$\hat{\beta}^{(k+1)} = \frac{|\nabla_{\theta} L_e|}{|\nabla_{\theta} L_I|} \quad (1)$$

式中 L_e, L_B 和 L_I 分别对应 N-S 方程、边界条件和初始条件的损失函数; α, β 分别为自适应权重系数,其平衡微分方程和初边值条件对损失函数的贡献。NSFnets 设计了自动微分计算层,因而理论上可不受空间网格和时间间隔的限制。

Jin 等^[8]采用 NSFnets 实现了高精度长时湍流模拟,如图 3 所示。特别地,在不需要改变 NSFnets

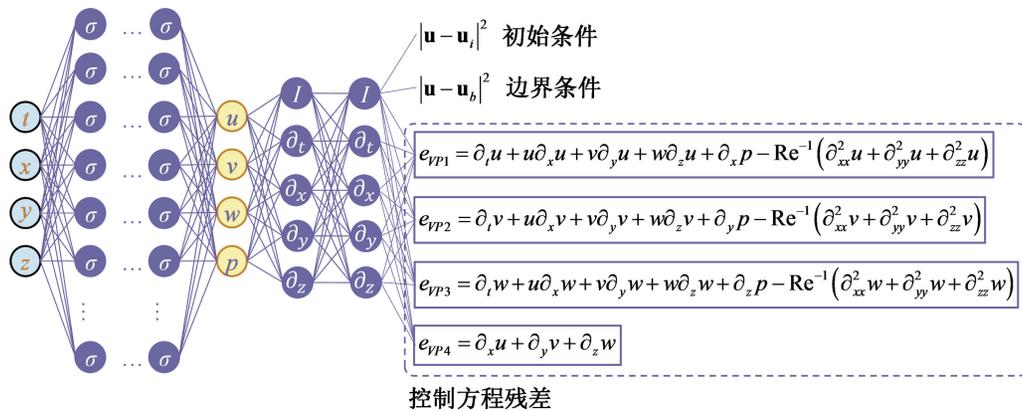


图 2 NSFnets 网络架构^[8]

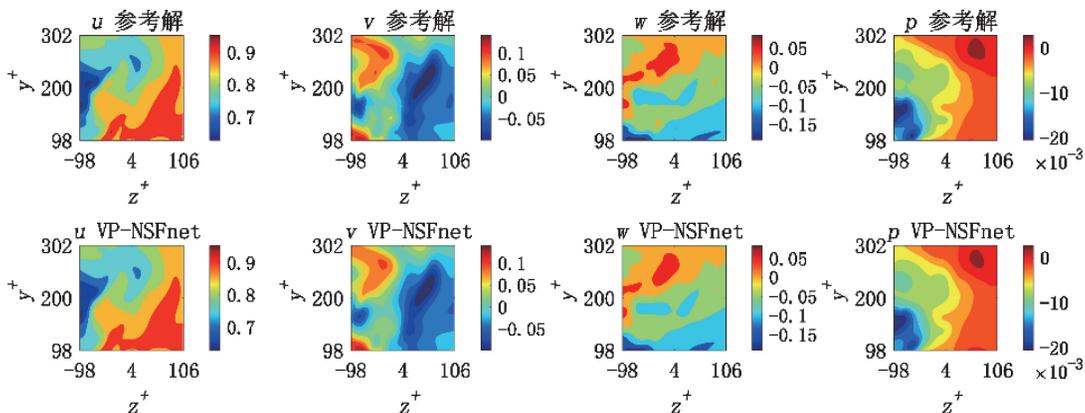


图 3 长时湍流模拟;DNS 参考解和 NSFnet 解在 $t^+ = 24.67$ 时刻 z - y 平面瞬态流场^[8]

架构下,可以与正向适定问题相同的计算代价,求解边界条件不完备或含噪声的 N-S 方程不适定问题和反问题,且能获得高精度解,而传统计算流体力学(Computational Fluid Dynamics, CFD)不能求解此类问题。

PINNs 不仅可求解 N-S 方程,亦可求解波动方程及其反问题。在已知部分位移监测数据时, Karimpouli 等^[9]基于 PINNs 求解了一维地震波动方程反问题,精确反演了位移场与地震波传播速度,并发现 PINNs 比高斯随机过程在反演地震波传播速度时具有更高精度。

PINNs 求解微分方程时,在某些复杂流动下,损失函数在网络训练中可能无法降低于阈值,从而无法保证解满足方程,又因网络涉及二阶导数,自动微分计算效率低。Chen 等^[10]和 Sirignano 等^[11]提出了改进的方法,但上述问题仍未很好解决。

网络时空表征求解方法对不同参数和初边值条件需重新训练网络,求解效率较低。基于神经网络算子通用近似定理,参数化非线性偏微分方程算子学习求解方法得到了广泛研究。Lu 等^[12]基于神经网络算子通用近似定理,提出了建立微分方程参数函数空间到解函数空间映射的 DeepONet。为增强 DeepONet 物理约束, Wang 等^[13]在损失函数中增加了方程残差,有效提升了精度,但网络训练效率明显降低。Li 等^[14]提出了求解参数化非线性偏微分方程的傅里叶神经算子(Fourier Neural Operator, FNO),如图 4 所示。FNO 建立了参数函数空间 $\mathcal{A}=\mathcal{A}(D; \mathbb{R}^{d_a})$ 到解函数空间 $\mathcal{U}=\mathcal{U}(D; \mathbb{R}^{d_u})$ 的映射关系。针对参数函数 $a(x) \in \mathcal{A}$,首先由神经网络 $P: \mathbb{R}^{d_a} \rightarrow \mathbb{R}^{d_v}$ 投影到高维空间函数 $v_0(x) = P(a(x))$;其次采用包含以 ϕ 为参数非局地核积分算子 $\mathcal{K}(a; \phi)$ 、局地线性变换 W 、局地非线性激活函数 σ 的傅里叶层迭代更新: $v_{i+1}(x) = \sigma(Wv_i(x) + (\mathcal{K}(a; \phi)v_i)(x))$,非局地核积分算子 $\mathcal{K}(a; \phi)$ 通过傅里叶变换 \mathcal{F} 转化为乘积运算显著提升计算效率

$$(\mathcal{K}(a; \phi)v_i)(x) = \mathcal{F}^{-1}(R_\phi \cdot (\mathcal{F}v_i))(x) \quad (2)$$

最后,由神经网络 $Q: \mathbb{R}^{d_v} \rightarrow \mathbb{R}^{d_u}$ 投影到解函数 $u(x)$

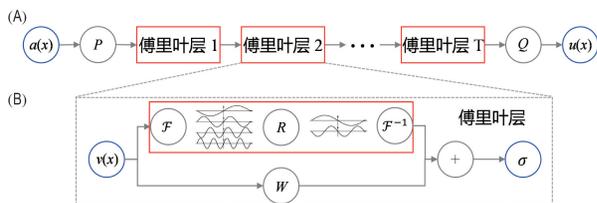


图 4 傅里叶神经算子: A. 傅里叶神经算子架构; B. 傅里叶层^[14]

$=Q(v_T(x))$ 。

当前,微分方程物理机器学习求解方法的逼近精度、训练收敛性和求解效率仍不及传统数值求解方法,该问题是一个富有价值且面临巨大挑战的研究课题。

2.2 数值计算—机器学习混合方法

传统数值计算方法中某些模块控制着计算精度或计算效率,利用大数据建立这些模块的机器学习模型,并嵌入传统数值计算方法,可以显著提高数值计算精度和效率(例如流体力学的湍流模型和动力学的材料或构件本构关系模型)。机器学习模型可以在数值计算中保持不变,也可以利用数值计算中产生的数据微调机器学习模型参数^[15](称之为主动学习策略)。本文以湍流模型为例,介绍数值计算—机器学习混合方法研究进展。

传统半经验半理论湍流模型普适性和精度较差。Jiang 等^[16]利用湍流大数据,提出了湍流模型物理机器学习统一网络架构,并将其嵌入传统 CFD 数值计算软件 OpenFOAM,求解流体控制方程得到结构流速场和压力场,网络架构如图 5 所示。受湍流代数模型启发,该网络设计两个子网络分别学习湍流模型的基和系数;其次,设计网络输入输出满足扩展伽利略不变性、尺度不变性、对称性和唯一性,

$$f_1 \odot f_2(\mathbf{q}, \mathbf{RQR}^T; \theta_\pi) = \mathbf{R}[f_1 \odot f_2(\mathbf{q}, \mathbf{Q}; \theta_\pi)]\mathbf{R}^T \quad (3)$$

$$f_1: \mathbf{q}' = \{s'_m, \omega'_m\} \mapsto \mathbf{g}' = \{g_1, g_2, \dots\} \quad (4)$$

$$f_2: \mathbf{Q} = \{\mathbf{s}, \boldsymbol{\omega}\} \mapsto \mathbf{T} = \{\mathbf{T}^{(i)}\}_{i=1}^{10} \quad (5)$$

式中 f_1 为湍流模型标量系数映射函数, f_2 为湍流模型张量基映射函数, $f_1 \odot f_2$ 代表数据模型必须符合旋转和反射不变性, \mathbf{R} 为任意正交基张量, \mathbf{q} 和 \mathbf{Q} 分别为标量系数网络和张量基网络输入向量, θ_π 为网络可训练参数, \mathbf{a} 为应力各向异性张量, \mathbf{s} 为平均应变速度梯度张量, $\boldsymbol{\omega}$ 为旋转速率张量, \mathbf{T} 为张量基。

采用聚类算法实现不同物理特征数据分类并重新采样保持数据平衡以实现公平性学习,并设计了提高湍流模型稀疏性和鲁棒性的损失函数

$$J(\boldsymbol{\theta}; \lambda_c; \lambda_w; \mathcal{D}) = \frac{1}{9N} \sum \| \mathbf{a}^{-1} \hat{\mathbf{a}} - \mathbf{I} \|_F^2 + \lambda_w \| \mathbf{w} \|_2^2 + \lambda_c \frac{1}{4N} \sum \| \mathbf{c} \|_2^2 \quad (6)$$

式中 N 为样本数, λ_w 和 λ_c 为正则化因子,第一项为应力各向异性应力张量无偏估计,第二项降低网络

复杂度,获得噪声不敏感模型封闭系数并防止过拟合,第三项缓解不适定问题。网络输出后连接可实现性模块,使网络输出各向异性应力张量满足流体物理性质。

以槽道流和管流数据训练网络,预测结果验证了网络精度、泛化能力和鲁棒性。

数值计算与机器学习混合方法在许多领域取得成功,例如 Zhang 等^[15]采用主动学习策略,构建具备第一性原理精度的神经网络原子间势函数,实现高精度大规模分子动力学模拟^[17]。当前面临的主要问题是机器学习输出可能不满足研究问题的物理约束,导致数值计算不收敛。

虽然深度学习具有很好的高维非线性函数逼近能力,但其对高频特征的逼近误差大,导致方程求解精度差、效率低、甚至不收敛,是今后值得关注的研究课题。

3 智能风工程

智能风工程主要包括流场和风场建模预测、气动力建模、结构风效应建模与预测、结构风灾损失预测、结构风效应诊断的机器学习方法,其科学本质是挖掘大数据高维空间共性特征,以高维非线性函数逼近流体控制方程和结构动力学方程的解(或解的部分性质)和模型,解决物理建模精度和普适性差的难题。

Jin 等^[18]基于钝体尾流的雷诺应力、旋涡生成长度、基底压力之间存在强相关性的流体物理性质,建立圆柱表面压力 p 与绕流场 (u, v, w) 映射的多尺度融合卷积神经网络,该网络隐含流体控制方程的性质,可捕捉压力脉动时空场平移不变性特征和精确时空信息,如图 6 所示。采用某些雷诺数工况数据 $(Re; p; u, v, w)$ 训练网络,而对其他雷诺数工

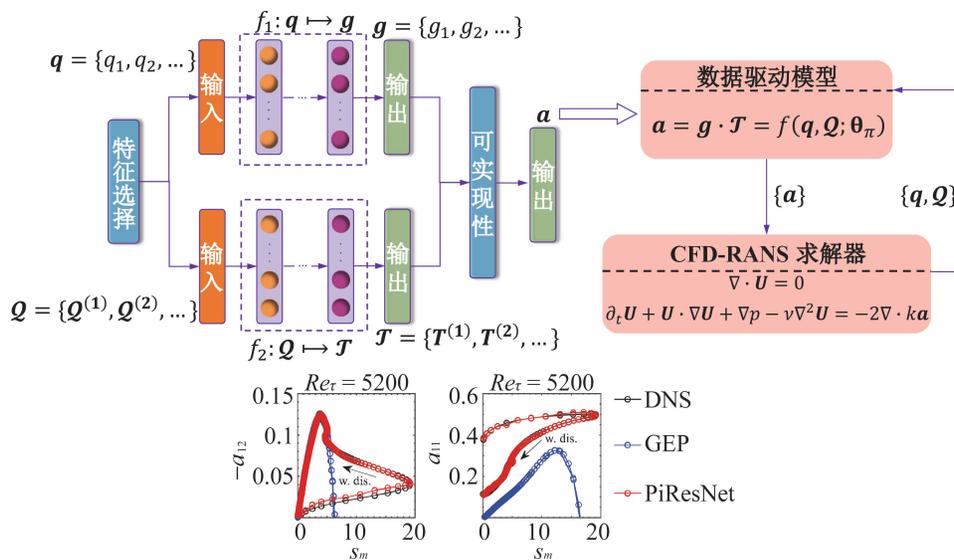


图 5 湍流模型物理机器学习统一网络架构与雷诺应力预测结果^[16]

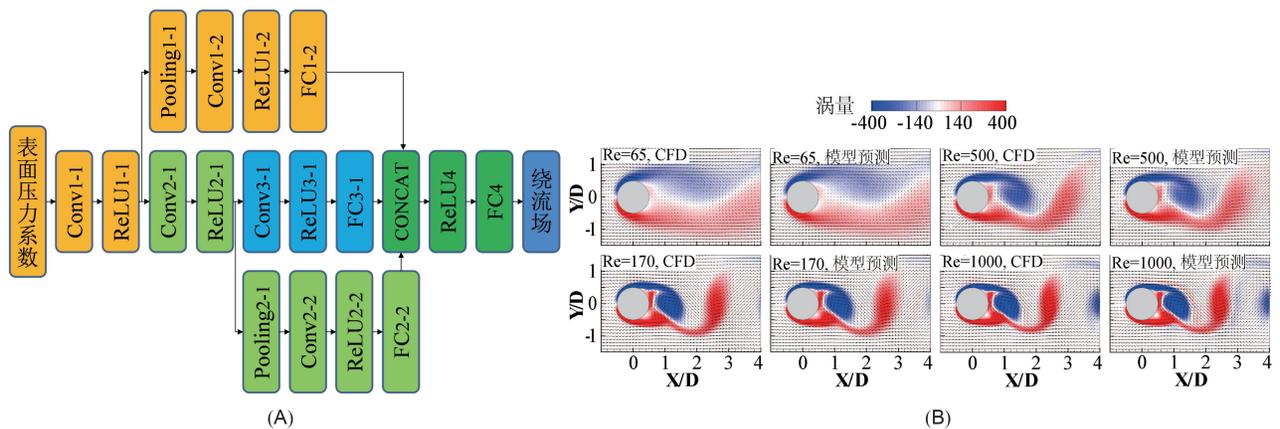


图 6 圆柱绕流场数据求解: A. 圆柱绕流场预测的多尺度融合卷积神经网络; B. 预测结果^[18]

况,可由圆柱表面压力精确预测绕流速度场。Yu 等^[19]提出结合小波变换、奇异谱分析以及 Elman 神经网络的风速预测模型,其使用小波分解将原始风速数据分解为多个子序列,然后使用奇异谱分析将频域最高的子序列进行降噪,再由各个子序列使用 Elman 神经网络进行预测并求和得到风速预测结果。Wang 等^[20]提出基于集成学习的风速概率预测方法,该方法首先建立长短时记忆神经网络(Long Short-term Memory, LSTM)和随机森林预测模型,然后将两个模型的预测结果作为高斯过程回归模型的输入并给出最终的预测值以及相应置信区间。

气动力建模是风工程经典问题之一,传统半经验半理论模型的普适性较差。挖掘多种工况大数据的共性特征,可建立普适性强的气动力模型,即建立风况、结构气动外形参数和结构响应与气动力的非线性映射关系。Hu 等^[21]构建了决策树回归、随机森林、极端梯度提升、生成对抗网络等四个高层建筑风压系数预测机器学习模型,对比结果表明生成对抗网络模型可以仅根据 30% 的训练数据预测风压。陈讷郁等^[22]基于大跨度桥梁气动力特性风洞试验数据,采用前馈神经网络建立了扁平箱梁和倒梯形梁截面外形参数与静力三分力系数非线性函数映射关系,预测了不同气动外形主梁的升阻力系数。Liao 等^[23]以气动外形控制点坐标、竖向和扭转等效质量、自振频率以及阻尼比为输入,颤振临界风速为输出,采用全连接神经网络,径向基函数神经网络,随机森林回归算法和梯度提升回归树算法对不同气动外形流线型箱梁颤振临界风速进行建模预测。Li 等^[24]采用 LSTM 建立桥梁颤振流固耦合作用气动力降阶模型,通过高保真流体数值模拟数据训练和验证表明,该模型可准确预测不同类型箱梁断面颤振气动力。

大型结构雷诺数高存在复杂的流动分离和动力学机制,很难建立准确的物理模型。基于大量风洞试验数据和现场原型结构监测数据,并融合传统风工程理论,采用物理增强数据范式,以风场参数、结构几何外形和动力特性为输入,以结构风振响应为输出,建立基于大数据的结构涡振、抖振和颤振的物理机器学习模型得到了广泛的研究,其本质是逼近流体控制方程和结构动力学方程,是研究流固耦合问题的新范式。涡振是非线性流固耦合效应,经典涡振理论无法适用实际大跨度桥梁非定常非一致自然风场,加之实际大跨桥梁阻尼机制极其复杂难以

建立准确的物理力学阻尼模型。涡振持续时间长,导致基于大数据的桥梁涡振机器学习模型难以训练。但涡振机理表明,桥梁涡振一般以单频为主振动, Li 等^[25]提出实际大跨桥梁涡振振幅递归神经网络模型和傅立叶基融合建模方法,建立了非定常非一致风场超高雷诺数大跨桥梁涡振响应预测物理机器学习模型:

$$y(t) = A(t)\sin[\omega t + \varphi],$$

$$\dot{A}(t) = f_1(A(t), U(t)), f_1: \{U_t, A_t\} \mapsto A_{t+1}$$

$$f_1: A_{t+1} = A_t + f_{N,1}(A_t, U_t; \mathbf{w}_{N,1})\Delta t, L_{f_1} = \frac{1}{N} \sum_{t=1}^N \|A_t - \tilde{A}_t\|_2^2 + \lambda_\omega \|\mathbf{w}_{N,1}\|_2^2 \quad (8)$$

式中 $A(t)$ 和 $\dot{A}(t)$ 为涡振幅值及其微分, ω 为涡振频率, $U(t)$ 为时变风速, $A_t = A(k\Delta t)$, $U_t = U(k\Delta t)$, $\mathbf{w}_{N,1}$ 为网络训练参数。该模型可准确预测实际大跨度桥梁长时涡振,如图 7 所示。

抖振是脉动风速诱发的结构随机振动,由 $\mathbf{S}_y(\omega) = \mathbf{H}(\omega)\mathbf{F}(\omega)\mathbf{F}(\omega)^* \mathbf{H}(\omega)^* \mathbf{H}(\omega)^* \mathbf{H}(\omega)^*$ 计算, $\mathbf{S}_y(\omega)$ 和 $\mathbf{F}(\omega)$ 分别为抖振响应功率谱、抖振荷载傅立叶变换和结构频响函数。基于抖振理论启发, Laima 等^[26]构建了 $\mathbf{H}(\omega)$ 和 $\mathbf{F}(\omega)$ 双神经网络,且 $\mathbf{H}(\omega)$ 和 $\mathbf{F}(\omega)$ 通过 $\mathbf{S}_y = \mathbf{H}\mathbf{F}\mathbf{F}^* \mathbf{H}^*$ 强制连接,形成抖振响应物理机器学习模型,如图 8 所示,该模型可准确预测实际大跨桥梁抖振响应,而传统方法因抖振荷载和结构物理力学模型建模困难,预测的误差很大。

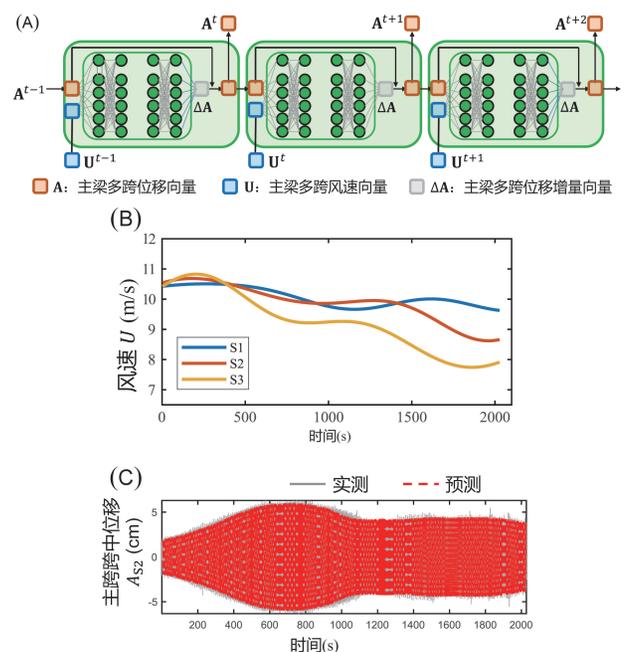


图 7 大跨度桥梁涡振物理机器学习模型及预测结果^[25]

颤振是小参数敏感非线性动力学问题,网络累积误差使长时预测十分困难, Li 等^[27]提出嵌入动力学控制方程计算桥梁颤振响应和气动力的 LSTM 神经网络, LSTM 表征气动力 P_{se}^{t+1} 与气动外形 S 、风速 U 和振动 $\{x^t, \dot{x}^t\}$ 之间的函数映射关系, f_2 为嵌入的动力学控制方程,利用 LSTM 输出的气动力 P_{se}^{t+1} 和动力学方程计算 LSTM 下一步状态 x^{t+1} ,如图 9 所示,该网络架构保证每一时间步桥梁颤振响应均满足动力学方程,避免误差累积,解决了小参数敏感问题,实现不同气动外形桥梁非线性颤振气动力和响应长时准确预测,并准确给出颤振临界风速。

结构风灾损失预测是风工程的重要研究内容。Huang 等^[28]以风速、风攻角、建筑尺寸、屋面坡度、地形粗糙度等变量为输入,屋面损毁比例为输出,采用深度神经网络建立了屋面损坏的快速预测模型,对风暴潮期间不同工况下屋面损毁情况进行了快速评估。

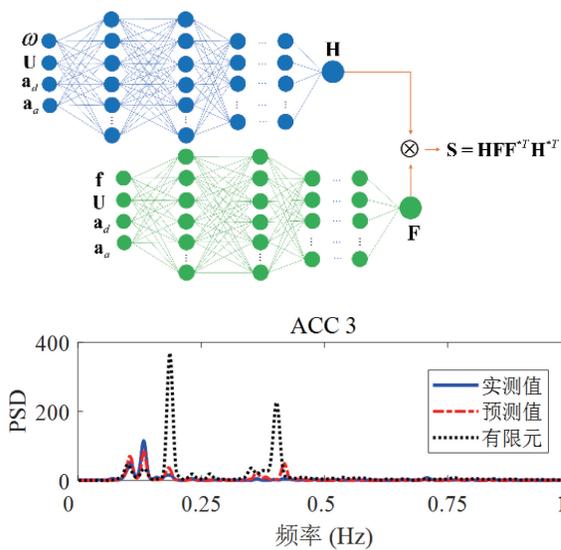


图 8 桥梁抖振物理机器学习网络构架和预测结果^[26]

结构特殊结构风效应诊断可为研究结构风灾机理和风灾评估奠定基础。通过构建表征结构风效应的高维特征空间,可实现高维空间无监督和有监督风效应自动准确诊断,高维特征空间能更准确地表征特殊风效应的物理性质。Li 等^[29]建立了表征桥梁涡振的能量时域和频域二维特征空间,发现二维特征空间内不同振动存在不同聚类模式,提出大跨度桥梁涡振自动诊断密度聚类算法。Arul 等^[30]和 Lim 等^[31]进一步将特征空间维数增加,在某高层建筑和某斜拉桥上实现了涡振的机器学习自动识别。

智能风工程研究面临的挑战之一是数据不完备性,尤其来流风速场不完备性,导致无法保证网络输入与输出映射关系的唯一性;其次,当前一个网络仅适用一座结构,应采用迁移学习网络架构,或将结构参数和风速场作为输入变量集,建立某一类风效应预测的统一网络。

4 智能地震工程

当前智能地震工程的研究主要包括地震动场机器学习模型、结构非线性滞变机器学习模型和结构地震响应快速计算的机器学习模型以及震后结构和城市工程系统损伤评估机器学习方法,其主要通过机器学习模型逼近波动方程(地震动)和结构动力学方程(结构地震响应)的解,并为增强模型泛化能力可嵌入控制方程和相关的物理性质。

地震动场特征和地震动参数预测模型是地震工程的基础。近年来,机器学习在震动领域取得重要进展, DeVries 等^[32]建立基于主震预测大震后余震分布的机器学习模型,精度远高于传统库仑破裂应力变化法; Khosravikia 和 Clayton^[33]采用神经网络、随机森林等建立了美国俄克拉荷马、堪萨斯和德克萨斯地震动参数预测模型。Mousavi 和 Beroza^[34]全面综述了人工智能对地震学发展的推动

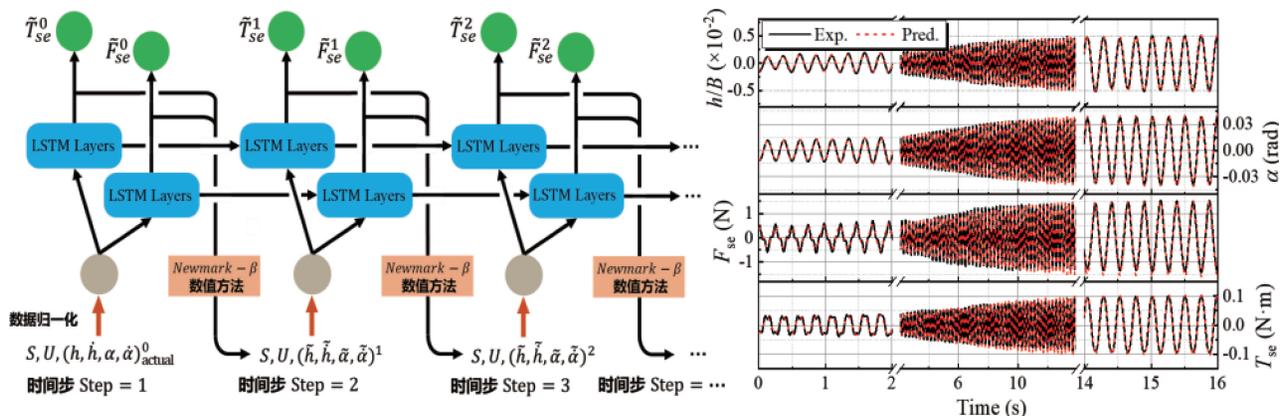


图 9 桥梁颤振物理机器学习网络构架与预测结果^[27]

作用,该领域拥有地震动大数据,为机器学习应用奠定了很好基础。地震动场特征主要由波动方程控制,上述机器学习模型隐含波动方程,网络输出本质是逼近波动方程解的部分性质。

基于大数据的结构非线性滞变模型机器学习建模方法和结构地震响应机器学习计算方法也逐渐成为地震工程研究热点。王和樊、Wang 等建立了结构滞变模型机器学习智能计算框架 DeepSNA,将输入划分为与结构固定属性相关的静态特征和与不同加载路径相关的动态特征,采用深度与交叉网络建立表示学习模型进行静态特征建模,采用 Transformer 网络建立具有历史依赖效应的力学响应预测模型进行动态特征建模^[35, 36]。Zhang 等^[37]建立了计算结构地震非线性响应的 LSTM 网络,并在网络架构中考虑了不同时间步之间结构响应的依赖关系和地震动输入与结构响应输出之间因果关系,如图 10 A 所示。Zhang 等^[38]进一步提出了求解结构非线性地震响应的物理融合多 LSTM 架构,其中第一个 LSTM 以地震动为输入、以非线性响应(速度、位移、滞变位移)为输出,另附加 LSTM 以第一个 LSTM 模化的非线性响应为输入、隐式输出非线性恢复力或状态变量,损失函数由数据损失函数和方程损失函数构成,网络架构如图 10 B 所示。基

于较少观测数据,Zhang 等^[38]使用该网络精确求解了三层框架结构非线性地震响应与 Bouc-Wen 模型。该类方法在建模中充分嵌入了方程物理约束,提升了模型泛化能力。基于 LSTM 建立地震动和结构响应之间映射关系本质是隐式地逼近结构动力学方程的解。

震后单体结构和城市工程系统地震破坏评估是地震工程的重要内容。卫星遥感技术、无人机、机器人和城市密集分布的视频摄像系统及智能手机等群智感知技术,可获取大量地震灾后图像和视频数据,基于图像和视频大数据的单体结构和大规模城市工程系统地震破坏识别的计算机视觉技术,可快速自动评估地震灾情,深刻变革传统人工现场调查灾害评估和管理模式。构件、单体结构、工程群、城市工程系统尺度不同,地震破坏识别任务亦不同。针对工程群和城市工程系统,主要从卫星遥感图像呈现的稠密建筑群中识别出单体结构及其倒塌破坏,Cui 等^[39]提出改进多头注意力机制 Swin Transformer 骨干网络提取震后稠密建筑群的空间相关特征,实现复杂场景下稠密建筑群及其破坏状态识别,如图 11 所示。针对构件和单体结构及其损伤,地震破坏会使构件几何形状与边界特征产生变化,Wang 等^[40]提出几何约束一致性卷积神经网络(Convolutional Neural Networks, CNN),实现建筑构件精准语义分割,获得结构地震损伤空间分布。

基于图像识别结构局部地震破坏,并不能给出结构剩余抗震能力,Miao 等^[41]以震损构件参数和图像为输入,经过 CNN 计算,输出震损构件地震损伤系数,建立了震损构件图像与其地震破坏等级的定量关系。Hoskere 等^[42]开发了基于物理图模型的三维合成建模环境,获得建筑群震后破坏多视角无人机图像,用于数据增强辅助网络训练和基于图像的结构地震破坏程度定量评估。Lu 等^[43]提出将数值模拟建筑群倒塌分布与无人机拍摄的真实建筑倒塌分布进行对比,寻找最接近的数值模拟结果确定地震破坏状态。

从城市密集分布的摄像系统和智能手机拍摄的大量地震中结构振动视频提取结构地震响应,可揭示真实结构地震行为并进行震后定量评估。Zhao 等^[44]提出基于单目相机结构稠密地震响应识别网络,为解决结构大变形严重破坏后单元难识别及数据样本过少问题,提出结构大变形随机生成数据方法,并设计神经网络识别大变形前、后结构单元;其次设计另一子网络识别视频每一帧结构单元姿态参

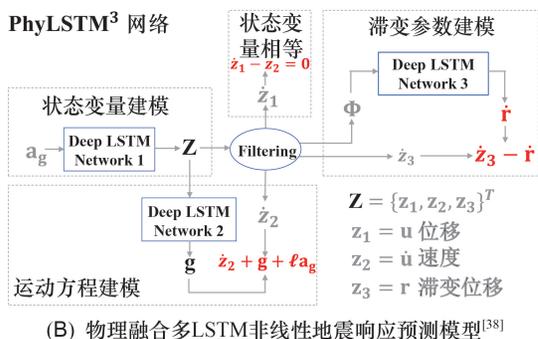
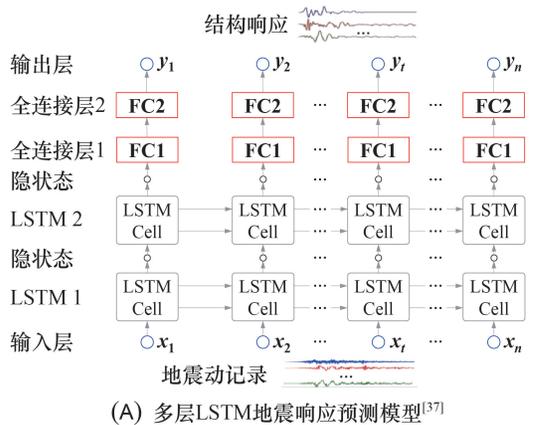


图 10 地震动与结构响应的 LSTM 模型

数及其对应物理空间坐标,得到每一单元位移响应,如图 12 所示。因单元数即为感知点数,因此只用一个相机数据即可得到结构稠密地震响应。

智能地震工程的研究面临的挑战之一是大震和超大震的地震动场数据和结构破坏数据匮乏;其次,结构非线性地震响应数值计算误差较大,基于计算数据建立机器学习模型预测结构地震响应并不能提高精度,应聚焦基于试验数据建立结构地震响应预测机器学习模型,研究大规模城市工程系统地震破坏预测机器学习模型;建立城市工程系统地震灾后快速评估和物理—数据交互(实—虚)管理系统也是值得关注的课题。

5 土木工程防灾减灾智能设计

土木工程传统设计流程是艺术设计、功能设计和结构设计,艺术设计以主观创造性为特征,功能设计和结构设计遵循相关的物理力学理论。机器学习的生成能力尤其是近年人工智能大模型为机器艺术设计或者基于数学的艺术设计开辟了崭新的范式,

也将土木工程设计全过程统一到数学计算框架中。图 13 给出了土木工程防灾减灾智能设计统一架构,包括创意设计、功能设计、结构智能计算与设计、艺术渲染、图纸智能生成。

创意设计用于确定土木工程艺术形式和风格,并为功能设计和结构设计提供空间设计域。生成网络创造能力的数学原理是:网络学习已有数据高维空间概率分布,再从概率分布随机抽样生成新数据,生成土木工程新艺术形式和风格。Qian 等^[45]发现土木工程几何外形特征的稀疏性,提出自稀疏生成对抗网络 Self-Sparse GAN 和基于 Self-Sparse GAN 无约束建筑几何外形智能设计方法;但土木工程创意设计往往需要体现环境、文化、功能等用户偏好,进一步提出了用户偏好建筑几何外形智能设计方法^[46],包括形状偏好模块和建筑融合模块,形状偏好模块允许输入用户手绘草图或文本,并提出自相似分数指标评价几何外形相似度;建筑融合模块允许用户添加艺术风格和当地文化等偏爱元素,如图 14 所示。采用智能设计方法可以在数秒内生成

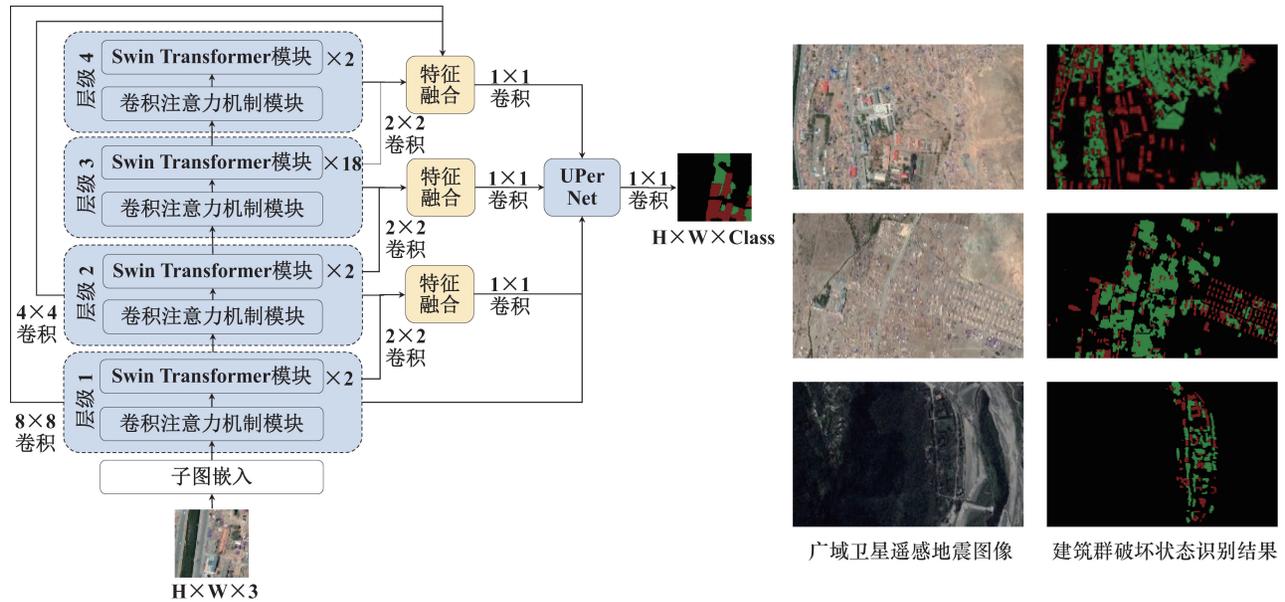


图 11 建筑群地震破坏状态识别的改进 Swin Transformer 和多层级特征融合 CNN^[39]

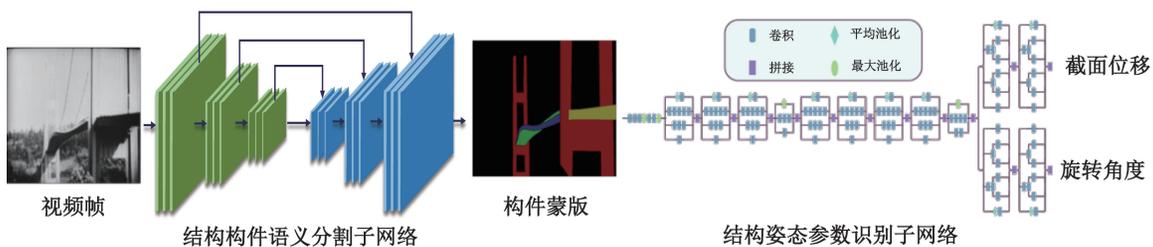


图 12 结构稠密地震响应识别 Structure-PoseNet^[44]

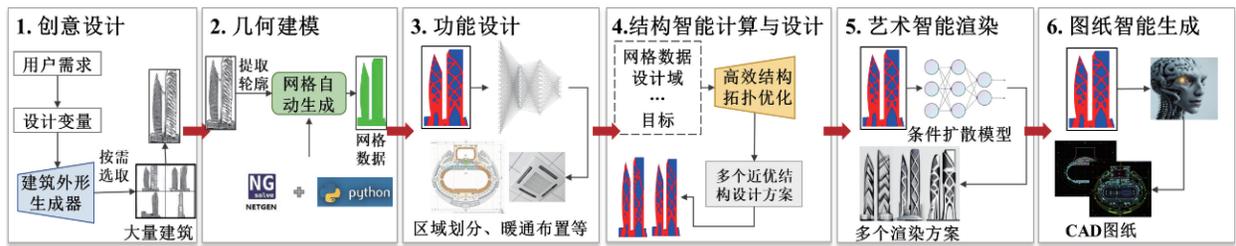


图 13 土木工程防灾减灾智能设计机器学习统一框架

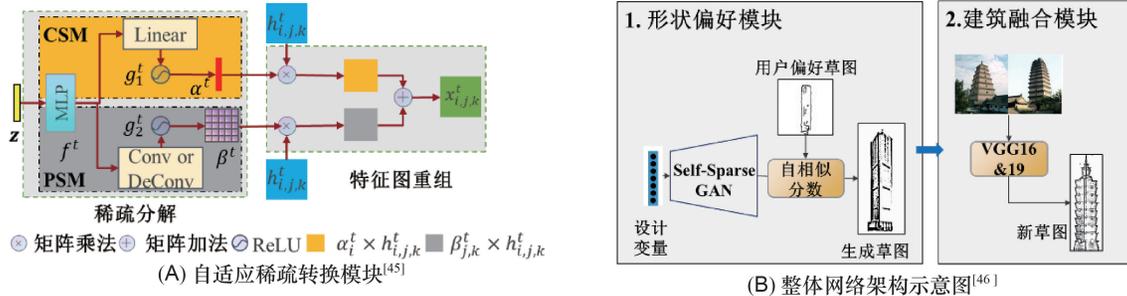


图 14 自稀疏生成对抗网络与土木工程艺术创意设计方法

数以万计具有特定主题但仍具有足够多样性的土木工程艺术创意方案。

功能设计主要确定建筑空间系列功能,包括建筑平面设计和建筑使用功能设计等,具有复杂性和非线性特征,是一类复杂优化问题。Merrell 等^[47]利用计算机图形学,提出由贝叶斯网络学习真实数据,自动生成建筑平面布局的设计方法;Chaillou 等^[48]提出 ArchiGAN 用于建筑平面图的设计,该网络通过嵌套三个 Pix2Pix GAN 模型生成楼层平面布局;廖等^[49]和 Liao 等^[50]提出了用于剪力墙平面布置的智能设计方法,并在多个住宅建筑结构上进行了验证。

结构设计包括力学分析(含风和地震等防灾减灾设计)和结构构件配筋设计等。当前,基于机器学习的拓扑优化设计和基于深度强化学习的智能设计方法在航天、汽车等诸多领域得到广泛研究,但在土木工程领域的研究还较少。Qian 等^[51]以神经网络和 Sigmoid 激活函数逼近拓扑描述函数(TDF),

$$f(x) = \sum_i w_i A_i(x) = \sum_i w_i e^{-\alpha^2 \|x-x_i\|^2},$$

$$\rho(x) = \frac{1}{1 + e^{-f(x)}} \quad (9)$$

式中 w_i 为神经网络权重, $\rho(x)$ 是连续密度值。因 Sigmoid 函数连续可导,从而将传统水平集无导数优化问题转换为基于梯度的优化问题,提出了结构智能设计高效显式拓扑描述函数增强神经网络方

法,通过拉格朗日乘子法将拓扑约束优化问题转化为网络优化问题,实现了高效三维结构智能设计(图 15)。设计中可采用有限元方法或智能方法进行力学计算。

完成初步结构设计,需进行结构构件配筋等设计。Jeong 和 Jo^[52]利用深度强化学习设计符合美国混凝土协会规范的钢筋混凝土梁;Li 等^[53]提出了基于图神经网络和遗传算法的自动钢筋混凝土结构设计优化方法,自动识别符合规范要求的最佳无碰撞钢筋设计。

建筑渲染本质上是图像到图像之间的概率迁移。生成模型为建筑渲染源图像和目标图像概率迁移提供了深层特征迁移,其中扩散模型(Diffusion Models, DMs)^[54]因其强大分布匹配建模能力,为实现建筑智能渲染提供了有效机器学习算法,图 16 给出基于预训练条件隐扩散模型(Latent Diffusion Models, LDMs)^[55]的建筑智能渲染框架,将设计草图渲染为逼真建筑图像。

最后的图纸智能生成,DeepMind 使用 Transformer 建立了自动生成 CAD 草图的机器学习模型,初步探索了机器学习在图纸生成领域的应用^[56];Li 等^[57]基于 Transformer 技术,提出将手绘图解析为 CAD 命令的 Free2CAD。然而,更加符合工程实际应用场景的建筑图纸自动生成技术还需进一步研究。

土木工程防灾减灾智能设计将传统分割设计转

化为数学优化或数学逼近统一设计模式,当前仍处于起步和萌芽阶段,其面临的挑战包括机器学习艺术设计创造性及其数学原理,结构方案设计的创造性及其数学原理,高效智能计算理论,物理—数据(实—虚)交互统一设计平台。

6 展望与讨论

土木工程智能防灾减灾对土木工程学科将产生深远的影响,但当前尚处于起步和探索阶段,以下问题值得特别关注:

(1) 现阶段人工智能机器学习以大数据为特征,土木工程领域的的数据分散于各个实验室和企业,数据共享、数据标准、数据标签和数据平台是本领域发展的基础。

(2) 基于神经网络通用近似定理,机器学习网络可以在高维空间逼近任意非线性函数,且逼近误差与维数无关(多项式、小波等经典数值逼近方法的逼近误差随维数增加而增大)^[58, 59],但最近研究表明,神经网络对数据高频分量逼近能力较差^[60, 61],该问题会影响机器学习的求解精度以及网络的收敛性,严重限制其应用;大部分微分控制方程的物理机器学习求解效率仍低于传统数值计算方法,还缺乏重大突破性进展;不完备信息下输入输出映射关系

机器学习模型本质是反问题求解,解的唯一性、泛化能力和可解释性至关重要;基于大数据的机器学习模型可能给出不满足物理规律的预测结果,模型尚需尽可能多地嵌入物理知识。机器学习应用于土木工程防灾减灾领域,应加强对上述基础问题的研究。

(3) 建立智能风工程、智能地震工程和防灾减灾智能设计的统一大模型和统一理论应成为今后该领域重点研究的课题。

(4) 适应智能社会发展,应尽早布局具有自学习和自进化能力的土木工程智能防灾减灾理论和技术、土木工程泛在感知与边缘计算理论和技术、物理—数据(实—虚)交互灾害推演基础理论和统一平台的研究。

参 考 文 献

- [1] Bao YQ, Li H. Machine learning paradigm for structural health monitoring. *Structural Health Monitoring*, 2021, 20(4): 1353—1372.
- [2] Li SW, Laima SJ, Li H. Data-driven modeling of vortex-induced vibration of a long-span suspension bridge using decision tree learning and support vector regression. *Journal of Wind Engineering and Industrial Aerodynamics*, 2018, 172: 196—211.
- [3] Li SW, Li SC, Laima SJ, et al. Data-driven modeling of bridge buffeting in the time domain using long short-term memory network based on structural health monitoring. *Structural Control and Health Monitoring*, 2021, 28(8): e2772.
- [4] 金晓威, 赖马树金, 李惠. 物理增强的流场深度学习建模与模拟方法. *力学学报*, 2021, 53(10): 2616—2629.
- [5] Cai SZ, Mao ZP, Wang ZC, et al. Physics-informed neural networks (PINNs) for fluid mechanics: a review. *Acta Mechanica Sinica*, 2021, 37(12): 1727—1738.
- [6] Hermann J, Schätzle Z, Noé F. Deep-neural-network solution of the electronic Schrödinger equation. *Nature Chemistry*, 2020, 12(10): 891—897.
- [7] Raissi M, Perdikaris P, Karniadakis GE. Physics-informed neural networks: a deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational Physics*, 2019, 378: 686—707.
- [8] Jin XW, Cai SZ, Li H, et al. NSFnets (Navier-Stokes flow nets): Physics-informed neural networks for the incompressible Navier-Stokes equations. *Journal of Computational Physics*, 2021, 426: 109951.

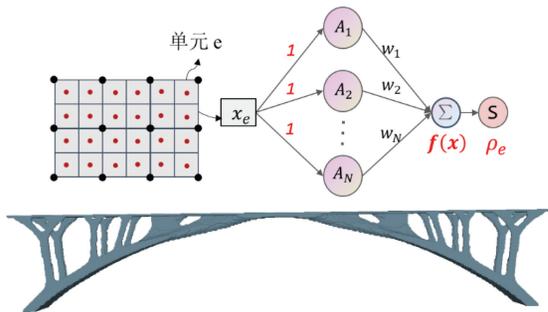


图 15 拓扑描述函数增强神经网络方法和智能设计的大跨度桥梁^[51]

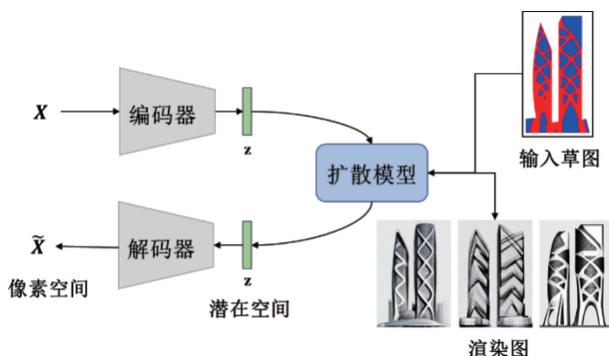


图 16 建筑智能渲染扩散模型网络

- [9] Karimpouli S, Tahmasebi P. Physics informed machine learning: seismic wave equation. *Geoscience Frontiers*, 2020, 11(6): 1993—2001.
- [10] Chen YT, Huang D, Zhang DX, et al. Theory-guided hard constraint projection (HCP): a knowledge-based data-driven scientific machine learning method. *Journal of Computational Physics*, 2021, 445: 110624.
- [11] Sirignano J, Spiliopoulos K. DGM: a deep learning algorithm for solving partial differential equations. *Journal of Computational Physics*, 2018, 375: 1339—1364.
- [12] Lu L, Jin PZ, Pang GF, et al. Learning nonlinear operators via DeepONet based on the universal approximation theorem of operators. *Nature Machine Intelligence*, 2021, 3(3): 218—229.
- [13] Wang SF, Wang HW, Perdikaris P. Learning the solution operator of parametric partial differential equations with physics-informed DeepONets. *Science Advances*, 2021, 7(40): eabi8605.
- [14] Li ZY, Kovachki N, Azizzadenesheli K, et al. Fourier neural operator for parametric partial differential equations. 2020: arXiv: 2010. 08895. <https://arxiv.org/abs/2010.08895>.
- [15] Zhang YZ, Wang HD, Chen WJ, et al. DP-GEN: a concurrent learning platform for the generation of reliable deep learning based potential energy models. *Computer Physics Communications*, 2020, 253: 107206.
- [16] Jiang C, Vinuesa R, Chen RL, et al. An interpretable framework of data-driven turbulence modeling using deep neural networks. *Physics of Fluids*, 2021, 33(5): 055133.
- [17] Lu DH, Wang H, Chen MH, et al. 86 PFLOPS deep potential molecular dynamics simulation of 100 million atoms with Ab initio accuracy. *Computer Physics Communications*, 2021, 259: 107624.
- [18] Jin XW, Cheng P, Chen WL, et al. Prediction model of velocity field around circular cylinder over various Reynolds numbers by fusion convolutional neural networks based on pressure on the cylinder. *Physics of Fluids*, 2018, 30(4): 047105.
- [19] Yu CJ, Li YL, Zhang MJ. An improved Wavelet transform using singular spectrum analysis for wind speed forecasting based on Elman Neural Network. *Energy Conversion and Management*, 2017, 148: 895—904.
- [20] Wang H, Zhang YM, Mao JX, et al. A probabilistic approach for short-term prediction of wind gust speed using ensemble learning. *Journal of Wind Engineering and Industrial Aerodynamics*, 2020, 202: 104198.
- [21] Hu G, Liu LB, Tao DC, et al. Deep learning-based investigation of wind pressures on tall building under interference effects. *Journal of Wind Engineering and Industrial Aerodynamics*, 2020, 201: 104138.
- [22] 陈讷郁, 葛耀君. 基于人工神经网络的典型桥梁断面气动参数识别. *土木工程学报*, 2019, 52(8): 91—97.
- [23] Liao HL, Mei HY, Hu G, et al. Machine learning strategy for predicting flutter performance of streamlined box girders. *Journal of Wind Engineering and Industrial Aerodynamics*, 2021, 209: 104493.
- [24] Li T, Wu T, Liu Z. Nonlinear unsteady bridge aerodynamics: reduced-order modeling based on deep LSTM networks. *Journal of Wind Engineering and Industrial Aerodynamics*, 2020, 198: 104116.
- [25] Li SW, Laima SJ, Li H. Physics-guided deep learning framework for predictive modeling of bridge vortex-induced vibrations from field monitoring. *Physics of Fluids*, 2021, 33(3): 037113.
- [26] Laima SJ, Feng H, Li H, et al. A Buffeting-Net for buffeting response prediction of full-scale bridges. *Engineering Structures*, 2023, 275: 115289.
- [27] Li WJ, Laima SJ, Jin XW, et al. A novel long short-term memory neural-network-based self-excited force model of limit cycle oscillations of nonlinear flutter for various aerodynamic configurations. *Nonlinear Dynamics*, 2020, 100(3): 2071—2087.
- [28] Huang GQ, He H, Mehta KC, et al. Data-based probabilistic damage estimation for asphalt shingle roofing. *Journal of Structural Engineering*, 2015, 141(12): 04015065.
- [29] Li SW, Laima SJ, Li H. Cluster analysis of winds and wind-induced vibrations on a long-span bridge based on long-term field monitoring data. *Engineering Structures*, 2017, 138: 245—259.
- [30] Arul M, Kareem A, Kwon DK. Identification of Vortex-induced vibration of tall building pinnacle using cluster analysis for fatigue evaluation: application to burj khalifa. *Journal of Structural Engineering*, 2020, 146(11): 04020234.
- [31] Lim J, Kim S, Kim HK. Using supervised learning techniques to automatically classify vortex-induced vibration in long-span bridges. *Journal of Wind Engineering and Industrial Aerodynamics*, 2022, 221: 104904.
- [32] DeVries PM, Viégas F, Wattenberg M, et al. Deep learning of aftershock patterns following large earthquakes. *Nature*, 2018, 560(7720): 632—634.

- [33] Khosravikia F, Clayton P. Machine learning in ground motion prediction. *Computers & Geosciences*, 2021, 148: 104700.
- [34] Mousavi SM, Beroza GC. Deep-learning seismology. *Science*, 2022, 377(6607): eabm4470.
- [35] 王琛, 樊健生. 基于深度学习的土木工程结构全过程响应智能计算框架. *建筑结构学报*, 2023, 44(1): 259—268.
- [36] Wang C, Xu LY, Fan JS. A general deep learning framework for history-dependent response prediction based on UA-Seq2Seq model. *Computer Methods in Applied Mechanics and Engineering*, 2020, 372: 113357.
- [37] Zhang RY, Chen Z, Chen S, et al. Deep long short-term memory networks for nonlinear structural seismic response prediction. *Computers & Structures*, 2019, 220: 55—68.
- [38] Zhang RY, Liu Y, Sun H. Physics-informed multi-LSTM networks for metamodeling of nonlinear structures. *Computer Methods in Applied Mechanics and Engineering*, 2020, 369: 113226.
- [39] Cui LY, Jing X, Wang Y, et al. Improved swin transformer-based semantic segmentation of postearthquake dense buildings in urban areas using remote sensing images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2022, 16: 369—385.
- [40] Wang Y, Jing X, Chen WL, et al. Geometry-informed deep learning-based structural component segmentation of post-earthquake buildings. *Mechanical Systems and Signal Processing*, 2023, 188: 110028.
- [41] Miao ZH, Ji XD, Wu MH, et al. Deep learning-based evaluation for mechanical property degradation of seismically damaged RC columns. *Earthquake Engineering & Structural Dynamics*, 2023, 52(8): 2498—2519.
- [42] Hoskere V, Narazaki Y, Spencer BF Jr. Physics-based graphics models in 3D synthetic environments as autonomous vision-based inspection testbeds. *Sensors*, 2022, 22(2): 532.
- [43] Lu XZ, Zeng X, Xu Z, et al. Improving the accuracy of near real-time seismic loss estimation using post-earthquake remote sensing images. *Earthquake Spectra*, 2018, 34(3): 1219—1245.
- [44] Zhao J, Hu FQ, Xu Y, et al. Structure-PoseNet for identification of dense dynamic displacement and three-dimensional poses of structures using a monocular camera. *Computer-Aided Civil and Infrastructure Engineering*, 2022, 37(6): 704—725.
- [45] Qian WL, Xu Y, Li H. A self-sparse generative adversarial network for autonomous early-stage design of architectural sketches. *Computer-Aided Civil and Infrastructure Engineering*, 2022, 37(5): 612—628.
- [46] Qian WL, Yang F, Mei HY, et al. Artificial intelligence-designer for high-rise building sketches with user preferences. *Engineering Structures*, 2023, 275: 115171.
- [47] Merrell P, Schkufza E, Koltun V. Computer-generated residential building layouts. *ACM Transactions on Graphics*, 2010, 29: 1—12.
- [48] Chaillou S. ArchiGAN: Artificial Intelligence x Architecture// Yuan PF, Xie M, Leach N, et al. *Architectural Intelligence*. Singapore: Springer, 2020: 117—127.
- [49] 廖文杰, 陆新征, 黄羽立, 等. 剪力墙结构智能化生成式设计方法: 从数据驱动到物理增强. *土木与环境工程学报(中英文)*. (2022-07-21)/[2022-12-29]. <http://kns.cnki.net/kems/detail/50.1218.TU.20220720.1117.004.html>.
- [50] Liao WJ, Lu XZ, Huang YL, et al. Automated structural design of shear wall residential buildings using generative adversarial networks. *Automation in Construction*, 2021, 132: 103931.
- [51] Qian WL, Xu Y, Li H. A topology description function-enhanced neural network for topology optimization. *Computer-Aided Civil and Infrastructure Engineering*, 2023, 38(8): 1020—1040.
- [52] Jeong JH, Jo H. Deep reinforcement learning for automated design of reinforced concrete structures. *Computer-Aided Civil and Infrastructure Engineering*, 2021, 36(12): 1508—1529.
- [53] Li MK, Liu YH, Wong BCL, et al. Automated structural design optimization of steel reinforcement using graph neural network and exploratory genetic algorithms. *Automation in Construction*, 2023, 146: 104677.
- [54] Ho J, Jain A, Abbeel P. Denoising diffusion probabilistic models. *Advances in Neural Information Processing Systems*, 2020, 33: 6840—6851.
- [55] Rombach R, Blattmann A, Lorenz D, et al. High-resolution image synthesis with latent diffusion models. *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. New Orleans, LA, USA. IEEE, 2022: 10674—10685.
- [56] Ganin Y, Bartunov S, Li Y, et al. Computer-aided design as language. *Advances in Neural Information Processing Systems*, 2021, 34: 5885—5897.

- [57] Li CJ, Pan H, Bousseau A, et al. Free2CAD: parsing freehand drawings into CAD commands. *ACM Transactions on Graphics*, 2022, 41(4): 1–16.
- [58] Wojtowytsch S, Weinan E. Can shallow neural networks beat the curse of dimensionality? A mean field training perspective. *IEEE Transactions on Artificial Intelligence*, 2020, 1(2): 121–129.
- [59] Siegel JW, Xu JC. Characterization of the variation spaces corresponding to shallow neural networks. 2021; arXiv: 2106.15002. <https://arxiv.org/abs/2106.15002>.
- [60] Xu ZQJ, Zhang YY, Xiao YY. Training behavior of deep neural network in frequency domain. //Gedeon T, Wong K, Lee M. *International Conference on Neural Information Processing*. Cham: Springer, 2019: 264–274.
- [61] Xu ZQJ, Zhang YY, Luo T, et al. Frequency principle: Fourier analysis sheds light on deep neural networks. *Communications in Computational Physics*, 2020, 28(5): 1746–1767.

State-of-the-Arts in Artificial Intelligence for Disaster Prevention and Mitigation of Civil Engineering

Jun Ji¹ Hui Li^{2*}

1. *Department of Engineering and Material Sciences, National Natural Science Foundation of China, Beijing 100085*

2. *School of Civil Engineering, Harbin Institute of Technology, Harbin 150090*

Abstract Based on the Project of “Disaster resilience of urban engineering structures and intelligent disaster prevention and mitigation” under Science Fund for Creative Research Groups (Grant No: 51921006) and Integrated Project of “Construction of database for high Reynolds Number turbulence and integrated research on machine learning-based turbulence” under Major Research Plan (Grant No: 92152301), the state-of-the-arts in artificial intelligence (AI) for disaster prevention and mitigation of civil engineering (DPMCE) is reviewed, including the disciplinary logic based on mechanics and challenges issues of traditional DPMCE, machine learning paradigm for solving governing equations in DPMCE, AI for wind engineering, AI for earthquake engineering, and AI for design methods of DPMCE. The critical issues in this field are discussed and recognized.

Keywords intelligence for disaster prevention of civil engineering; machine learning; AI for wind engineering; AI for earthquake engineering

(责任编辑 张强)

* Corresponding Author, Email: lihui@hit.edu.cn