

基于物理信息神经网络的非线性微分方程求解模型研究

葛淼彦¹ 李凯锋²
GE Miaoyan LI Kaifeng

摘要

微分方程在工学领域广泛应用,但传统数值方法在非线性问题时存在效率低、适应性弱的局限。物理信息神经网络通过将微分方程约束嵌入损失函数,实现数据驱动的非网格化求解。文章以非线性微分方程为例并结合数值实验,探讨 PINN 在非线性和微分方程求解中的优化。研究通过对比 tanh、ReLU 等激活函数及不同网络参数(深度、神经元数量、学习率)对模型性能的影响,验证 PINN 的有效性。研究表明, PINN 框架在非线性和微分方程求解中具有良好的泛化能力,为复杂微分方程求解提供了新的技术路径; tanh 激活函数在导数传播中表现更优,网络深度超过 5 层后性能提升有限,学习率在 $[0.0001, 0.001]$ 区间可平衡收敛速度与稳定性。

关键词

物理信息神经网络;非线性微分方程;多目标损失函数

doi: 10.3969/j.issn.1672-9528.2025.10.028

0 引言

微分方程作为描述自然规律和工程现象的数学工具,在流体力学、量子力学、气候建模等领域应用甚广。然而在求解实际问题中的微分方程时,常常需要面对高阶微分、非线性、尺度多等复杂情况。传统数值解法的代表包括有限差分法、有限元法等,这类方法实际应用时依赖于网格划分,在面对维度高、边界复杂或非线性强的问题时,也不免存在计算效率低下、适应性弱的局限。因此探索新的求解方法,提高求解效率和精度,逐渐成为当前微分方程研究领域的重要课题。

随着深度学习在各领域的广泛应用^[1],物理信息神经网络(physics-informed neural networks, PINN)应运而生。PINN 通过将微分方程约束嵌入神经网络的损失函数,实现了数据驱动的非网格化求解。PINN 的概念最早由 Raissi 等人^[2]于 2019 年提出,通过将数据驱动和物理模型相结合,充分利用已知的物理规律和有限的信息,并成功应用于非线性偏微分方程的正问题和反问题求解。随后, Lu 等人^[3]开发的 DeepXDE 库通过自适应残差优化提升了 PINN 的训练效率。Wang 等人^[4]提出 NAS-PINN,结合神经网络架构搜索技术优化模型结构。此外,李晓峰等人^[5]针对海洋孤立波问题构建了 PIRBF 模型,通过径向基函数改进 PINN 的非线性拟合能力。

然而,随着对微分方程的研究日渐深入, PINN 的不足日渐显现,求解复杂问题时面临梯度消失、收敛速度慢等挑战。现有研究对非线性微分方程的探索不足,尽管 PINN 在普通方程中表现优异,非线性微分方程的导数约束会导致损失函数复杂化,加剧模型训练的不稳定性,限制了其实际应用。本文针对非线性微分方程,结合非线性微分方程的数值实验,探究网络优化方法。

1 物理信息神经网络原理

PINN 是一种将物理定律嵌入神经网络训练的深度学习框架,通过数据驱动并且结合物理约束,解决非线性偏微分方程的正向求解和逆向参数识别问题,其基本结构如图 1 所示。




图 1 PINN 网络结构

图 1 中左侧虚线框内是一般的神经网络,其基本结构一般包括输入层、隐藏层、输出层。输入数据 X 在经过预处理后进入输入层,随后在隐藏层中计算激活,最终经输出层处理后输出为结果 u 。神经网络的每个层都包含多个神经元,

1. 常州大学机械与轨道交通学院 江苏常州 2131642
2. 南京南瑞智慧交通科技有限公司 江苏南京 210031

每个神经元与上一层的所有神经元连接，每个连接都被赋予不同的权重值。

以输出层的第一个神经元为例， a_1 至 a_n 代表来自前一层神经元的全部数据，连接上的权重为 W_1 至 W_n 。数据 a 与权重 W 相乘后加上偏置 b ，经过激活函数 s 激活运算后，后层神经元输出结果为：

$$f(x) = \sigma\left(\sum_{i=1}^n W_i a_i + b\right) \quad (1)$$

图 1 右侧虚线框内描述的是自动微分的过程，可计算微分方程内的导数以及各项损失。

一般形式的微分方程表示为：

$$\begin{cases} \frac{\partial^k \mathbf{u}}{\partial t^k}(\mathbf{x}, t) = D[\mathbf{u}(\mathbf{x}, t)] \\ B[\mathbf{u}(\mathbf{x}, t)] = h(\mathbf{x}, t) \\ \frac{\partial^l \mathbf{u}}{\partial t^l}(\mathbf{x}, 0) = g(\mathbf{x}) \end{cases} \quad (2)$$

使用深度学习网络求解式 (2) 的微分方程时，模型训练必不可少的是损失函数，网络在最小化损失函数的过程，不断地更新模型的参数，从而使其逼近微分方程的解。PINN 神经网络的损失库函数组成包括 3 类损失，即方程残差项、边界条件项、初始条件项^[2]。

方程残差项 MSE_u 是 PINN 的核心损失项，一般用于衡量神经网络预测的解是否满足微分方程。 MSE_u 通过计算方程在一组随机采样点上的残差来实现，该损失项确保模型在训练过程中遵循物理定律，使得即使没有测量数据，也能通过物理约束来指导模型的学习。由式 (2) 的第一部分，可得方程残差项：

$$MSE_u = \frac{1}{N_u} \sum_{i=1}^{N_u} \left| \frac{\partial^k \mathbf{u}}{\partial t^k}(\mathbf{x}, t) - D[\mathbf{u}(\mathbf{x}, t)] \right|^2 \quad (3)$$

边界条件项 MSE_b 用于衡量模型预测的解是否满足边界条件，这能确保模型在训练过程中从正确的起点开始，从而提高预测的准确性。由式 (2) 的第二部分，可得边界条件项：

$$MSE_b = \frac{1}{N_b} \sum_{i=1}^{N_b} |B[\mathbf{u}(\mathbf{x}, t)] - h(\mathbf{x}, t)|^2 \quad (4)$$

初始条件项 MSE_l 用于衡量模型预测的解是否满足初始条件，确保模型在边界处的行为符合物理实际，避免在边界处出现不合理的偏差。由式 (2) 的第三部分，可得边界条件项：

$$MSE_l = \frac{1}{N_l} \sum_{i=1}^{N_l} \left| \frac{\partial^l \mathbf{u}}{\partial t^l}(\mathbf{x}, 0) - g(\mathbf{x}) \right|^2 \quad (5)$$

综合式 (3) ~ (5)，网络的总损失为：

$$\text{Loss} = aMSE_u + bMSE_b + cMSE_l \quad (6)$$

式中： a 、 b 、 c 为各损失项的权重系数，根据重要性平衡各项损失。通过最小化 Loss，使得模型的解趋近于解析解。

2 数值实验

为了探索 PINN 算法在求解非线性微分方程的优势以优化方案，本节将针对多种算例，利用 PINN 算法求解非线性微分方程，并研究不同激活函数、神经网络参数设置对训练效果的影响^[6]。

本文使用 Python 环境开展本工作中的所有计算，软件环境为 Python 3.8、PyTorch1.11、NumPy1.23.4、matplotlib 3.6.2，CUDA 版本为 11.3，cuDNN 版本为 8.2.1。测试采用的平台是 Intel(R) Core(TM) i7-13700KF (24 核，3.40 GHz) 和 NVIDIA GeForce RTX 4090。

2.1 PINN 求解非线性微分方程

本节将以非线性常微分方程为例，基于 PINN 神经网络求解方法求解具体的非线性微分方程，分析求解效果。非线性常微分用公式表示为^[7]：

$$\begin{cases} y'''(x) - y^2(x)e^{-x} = 0, x \in [0, 1] \\ y(0) = 1 \\ y'(0) = 1 \\ y(1) = e \end{cases} \quad (7)$$

该方程的解析解为：

$$y(x) = e^x \quad (8)$$

神经网络选用 5 个隐藏层，每层 64 个神经元，在 $[0, 1]$ 之间随机选取 100 个数据点进行训练，使用 Adma 优化算法迭代至收敛。

图 2 为 PINN 结果与解析解的对比图，实线代表 PINN 的输出结果；虚线代表解析解的结果。观察曲线可以发现，两条曲线基本完全重合，PINN 的解与解析解基本一致，说明 PINN 求解偏微分方程取得了较好的效果，PINN 能够较好地求解非线性常微分方程。




图 2 PINN 解与解析解对比

观察图 3 可以发现损失函数数值随迭代步数下降,在经过 41 次训练后,曲线下落速度减缓并趋向 0,由此可以判断模型已经收敛,最终 PINN 预测与解析解的误差低于 10^{-6} 并触发训练停止。综上所述, PINN 求解非线性微分方程时具有强大的拟合能力,模型容易收敛。




图 3 PINN 损失下降曲线

2.2 激活函数选取

激活函数是神经网络的关键组成部分,能够在神经元的输入中引入非线性变换,从而使网络具有学习和复杂表示的能力。为了探讨不同激活函数对微分方程求解的影响,并分析 PINN 任务中不同激活函数的性能差异,考虑非线性微分方程^[7]:

$$\begin{cases} y'''(x) + 2\alpha\beta y(x)y'(x) + 4\alpha^2 y'(x) = 0, x \in [0, 1] \\ y(0) = 1 \\ y'(0) = 0 \\ y(1) = 0 \end{cases} \quad (9)$$

式中: α 取 0.0524; β 取 110。

常用的激活函数包括 tanh、ReLU、LeakyReLU、ELU 等,不同的激活函数在复杂度、缓解梯度消失等方面各具优势。

本节实验中网络层数固定为 5 层,每层神经元个数为 64,学习率为 0.000 1,训练次数为 10 000 epoch,若 1 000 个 epoch 训练无提升则触发早停。

激活函数训练结果对比如图 4 所示,图中横轴为输入值,竖轴代表预测值。由此可知,ReLU、ELU、LeakyReLU 训练的模型的预测值与实际值差距较大,而 tanh 和 Sigmoid 作为激活函数能够训练出更好的模型。激活函数 tanh 不仅引入非线性特性,在中间输入范围内 tanh 对输入变化敏感,能够更好地捕捉特征差异。激活函数 Sigmoid 虽然非线性特性较弱,但其在函数上平滑的特性亦有助于稳定地训练。




图 4 不同激活函数下 PINN 解对比

图 5 为不同激活函数下模型训练时损失函数数值变化的曲线,其中横轴代表迭代训练步数,竖轴是损失函数的值。由图 5 可知,ELU、ReLU、LeakyReLU 作为激活函数时损失下降较慢且由于损失值在 1 000 步内没有提升而进入了早停,最终训练结果趋于欠拟合。tanh 和 Sigmoid 作为激活函数训练模型时损失函数收敛更快,并且收敛时 tanh 模型的损失值要低于 Sigmoid 模型,因此 tanh 更适合本节任务。




图 5 不同激活函数下 PINN 损失下降曲线

2.3 模型参数设置

PINN 网络深度通常为 4~10 层,每层 20~200 个神经元,具体参数设置取决于问题复杂度。此外,学习率的设置也影响着模型的性能。本节以式(10)为例^[7],探讨不同网络参数对求解的影响。

$$\begin{cases} y'''(x) + y(x)y''(x) - (y'(x))^2 + 2 = 0, x \in [0, 1] \\ y(0) = 0 \\ y'(0) = 0 \\ y(1) = 0 \end{cases} \quad (10)$$

网络尺寸按照表格所示设置了 4 种,优化器选择 Adam,学习率设置为 0.000 1,早停迭代步数设置为 1 000,训练结果如表 1 所示。

表 1 多种网络尺寸下模型训练结果

网络尺寸	迭代步数	误差值 /RMSE
[5, 20]	10 000	4.508 811e-05
[5, 64]	3 233	9.861 776e-07
[8, 20]	10 000	9.872 882e-05
[8, 64]	4 566	9.900 445e-07

由表 1 可知, PINN 网络设置为 5 层且每层 20 神经元时网络尺寸较小, 网络拟合能力有限, 因此即便迭代次数上升, [5, 20] 网络损失依旧大于 [5, 64] 网络的损失值, 属于欠拟合。类似的, [8, 20] 网络也属于欠拟合。对比 [5, 64] 网络和 [8, 64] 网络, 网络深度加深但是性能并未进一步上升, 损失值处于同一量级且相近, 从迭代步数上看 [5, 64] 网络更节约时间和硬件资源。

网络尺寸按照前文的经验取 [5, 64], 优化器选择 Adam, 学习率按照表格设置了 3 种, 早停迭代步数设置为 1 000, 训练结果如表 2 所示。

表 2 多种学习率下模型训练结果

学习率	迭代次数	误差值 /RMSE
0.01	2 300	3.746 522e-05
0.001	2 828	9.949 236e-07
0.000 1	3 233	9.861 776e-07
0.000 01	10 000	1.022 672e-05

表 2 中数据显示学习率选取为 0.001 和 0.000 1 时, 相较于另外两种都达到了较好的结果。学习率选取为 0.01 时明显损失较大且由于损失值许久无改善而早停, 这是因为学习率过大导致网络权重变化过大, 难以达到最优解。选取为 0.000 01 时损失持续下降, 但是学习率过小导致网络权重变化过小, 迭代速度也因此变慢。由此可见, 学习率选取为 0.001 和 0.000 1 时训练效果较好。

3 结论

本文聚焦 PINN 在微分方程中应用, 通过数值实验研究 PINN 在非线性微分方程求解的效果。首先通过数值实验验证 5 层 64 神经网络结构在 Adam 优化器作用下可实现与解析解小于 10^{-6} 的误差收敛; 进一步针对非线性方程的激活函数敏感性测试显示, tanh 函数在导数传播中表现出更优的梯度保持能力。模型参数优化实验发现, 网络深度超过 5 层后性能提升趋于饱和, 学习率设置在 [0.0001, 0.001] 区间可平衡收敛速度与稳定性。PINN 框架在非线性微分方程求解中展现出良好的泛化能力, 通过合理设计网络结构与优化策略, 可有效突破传统数值方法的局限性。

参考文献:

- [1] 姚泽远, 卜原玲, 韩伟. 基于深度神经网络与 Box-Behnken 响应面法的灵芝总三萜提取工艺优化 [J]. 南京工业大学学报 (自然科学版), 2023, 45(3): 347-354.
- [2] RAISSI M, PERDIKARIS P, KARNIADAKIS G E. Physics-informed neural networks: a deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations[J]. Journal of computational physics, 2019, 378: 686-707.
- [3] LU L, MENG X H, MAO Z P, et al. DeepXDE: a deep learning library for solving differential equations[J]. SIAM review, 2021, 63(1): 208-228.
- [4] WANG Y F, ZHONG L L. NAS-PINN: neural architecture search-guided physics-informed neural network for solving PDEs[J]. Journal of computational physics, 2024, 496: 112603.
- [5] LI X F, WANG H Y, YANG Y, et al. Deep learning-based solution for the KdV-family governing equations of ocean internal waves[J]. Ocean modelling, 2025, 194: 102493.
- [6] 陈新海, 刘杰, 万仟, 等. 一种改进的基于深度神经网络的偏微分方程求解方法 [J]. 计算机工程与科学, 2022, 44(11): 1932-1940.
- [7] WANG W. Discussion on solving differential equations by finite difference method and PINN method[J]. Advances in applied mathematics, 2023, 12(7): 3298-3310.

【作者简介】

葛森彦 (1996—), 男, 江苏扬州人, 硕士研究生, 助理实验员, 研究方向: 机器学习、计算机视觉。

李凯锋 (1995—), 男, 河南驻马店人, 硕士研究生, 助理工程师, 研究方向: 信息化集成、工业数字化平台体系建设、机器学习。

(收稿日期: 2025-05-08 修回日期: 2025-09-22)