

引文: 金凤, 郭祎, 张岩, 等. 基于硬约束和物理信息神经网络结合的天然气管网仿真新方法[J]. 天然气工业, 2025, 45(1): 164-174.
JIN Feng, GUO Yi, ZHANG Yan, et al. A new gas pipeline network simulation method based on BHC-PINN[J]. Natural Gas Industry, 2025, 45(1): 164-174.

基于硬约束和物理信息神经网络结合的天然气管网仿真新方法

金凤¹ 郭祎² 张岩³ 马秀云³ 刘斌⁴
焦健丰⁵ 殷雄² 徐海龙¹ 官敬¹ 温凯¹

1. 中国石油大学(北京)机械与储运工程学院 2. 国家石油天然气管网集团有限公司油气调控中心
3. 国家管网集团北京管道有限公司 4. 中国石油华北油田公司油气工艺研究院 5. 曼彻斯特大学化学工程与分析科学系

摘要: 随着天然气管网互联互通成环成网, 需要利用仿真技术模拟各种工况下的管网运行状态, 以提升管网的供气能力, 进而降低管网运行成本。现有的智能化仿真方法过于依赖数据驱动, 忽略了天然气流动机理, 导致精度与稳定性较差且结果不可解释。为此, 从机理角度分析了天然气流动基本控制方程与管网拓扑结构, 将机理信息耦合至深度学习的损失函数指导结构设计与训练, 形成了天然气管网物理信息神经网络 PINN (Physics-Informed Neural Network) 仿真模型; 然后描述了输入输出变量之间的耦合关系, 设计边界条件嵌入训练硬约束模式, 建立了硬约束和物理信息神经网络结合 BHC-PINN (Boundary Hard-Constraint Physics-Informed Neural Network) 的模型, 实现了天然气管网全时空状态的仿真监测。研究结果表明: ① PINN 模型将管道与拓扑结构的机理信息耦合进损失函数以提高模型的可解释性, 并借助管网进出口冗余数据提高了准确性, 实现了对管网压力流量的准确监测; ② 建立的边界硬约束模式, 使神经网络的输出强制满足边界条件, 得到的流量和压力仿真误差分别从 2.1% 和 0.32% 降低至 1.5% 和 0.082%, 训练的效率和速度分别提高了 48.5% 和 55.9%; ③ BHC-PINN 能实现管网任意位置气体流动状态的观测, 对于中间阀室压力的仿真最大误差为 0.2%。结论认为, 该新方法能准确仿真天然气管网内流动状态, 增强了数据驱动模型的可解释性, 并为天然气管网瞬态仿真提供了数据加机理混合驱动的新思路。

关键词: 天然气管道; 水力瞬态仿真; 物理信息神经网络; 硬约束模式

中图分类号: TE832 文献标识码: A DOI: 10.3787/j.issn.1000-0976.2025.01.014

A new gas pipeline network simulation method based on BHC-PINN

JIN Feng¹, GUO Yi², ZHANG Yan³, MA Xiuyun³, LIU Bin⁴,
JIAO Jianfeng⁵, YIN Xiong², XU Hailong¹, GONG Jing¹, WEN Kai¹

(1. College of Mechanical and Transportation Engineering, China University of Petroleum, Beijing 102249, China; 2. PipeChina Oil and Gas Control Center, Beijing 100000, China; 3. PipeChina Beijing Pipeline Co., Ltd., Beijing 100000, China; 4. Oil and Gas Technology Research Institute, PetroChina Huabei Oilfield Company, Renqiu, Hebei 062552, China; 5. Department of Chemical Engineering and Analytical Sciences, University of Manchester, Manchester M13, 9PL, UK)

Natural Gas Industry, Vol.45, No.1, p.164-174, 1/25/2025. (ISSN 1000-0976; In Chinese)

Abstract: With the interconnection and networking of gas pipelines, it is necessary to simulate the operation status of the pipeline network under various working conditions, so as to improve the gas supply capacity of the pipeline network and reduce the operation costs. The existing intelligent simulation methods rely heavily on data drive, but neglect the gas flow mechanism, resulting in poor accuracy and stability. And the results are uninterpretable. In this paper, the basic control equations of gas flow and the topological structure of the pipeline network are analyzed from the perspective of mechanism, the mechanism information is coupled to the loss function of deep learning to guide the structure design and training, and a physics-informed neural network (PINN) simulation model is established. Then, the coupling relationship between the input and output variables is described, the hard constraint mode of embedding boundary condition into training is designed, and a model integrating boundary hard constraint (BHC) and PINN, i.e. BHC-PINN model, is established, so that simulation monitoring of gas pipeline network under the full time-space state is realized. The following results are obtained. First, the PINN model couples the mechanism information of pipelines and topological structures into the loss function to improve the interpretability of the model, and utilizes redundant data of pipeline inlet and outlet to improve accuracy, so as to achieve the accurate monitoring of pipeline pressure and flow rate. Second, the established BHC-PINN model forces the output of the neural network to meet the boundary conditions, resulting in a decrease in flow rate and pressure simulation errors from 2.1% and 0.32% to 1.5% and 0.082%, respectively, and an increase in training efficiency and speed by 48.5% and 55.9%, respectively. Third, the BHC-PINN model can observe the gas flow state at any position in the pipeline network, with the maximum simulation error of the pressure in the intermediate valve chamber being 0.2%. In conclusion, the new BHC-PINN method can accurately simulate the flow state inside the gas pipeline network, enhance the interpretability of data-driven models, and provide a new idea of data and mechanism hybrid driving for transient simulation of gas pipeline network.

Keywords: Gas pipeline; Hydraulic transient simulation; PINN; BHC

基金项目: 国家自然科学基金面上项目“复杂供气管网大时滞非线性仿真模型构建与智能调控”(编号: 52174064)、国家自然科学基金项目“面向大规模成品油管网调度的数据解析与优化融合方法”(编号: 52202405)。

作者简介: 金凤, 女, 2000 年生, 博士研究生; 主要从事天然气站场智能化方面的研究工作。地址: (102249) 北京市昌平区府学路 18 号。ORCID: 0009-0007-4297-0290。E-mail: 2024310446@student.cup.edu.cn

通信作者: 温凯, 1983 年生, 副教授, 博士研究生导师, 博士, 本刊青年编委; 主要从事油气管网智能化方面的研究工作。地址: (102249) 北京市昌平区府学路 18 号。ORCID: 0000-0002-6455-3099。E-mail: kewin1983@126.com

0 引言

天然气作为清洁高效能源,在能源转型与综合能源体系中发挥着不可替代的作用^[1-2]。截至2023年年底,我国长输天然气管道总里程达到 11.8×10^4 km,基本形成了“西气东输、北气南下、海气登陆、就近供应”的供气格局^[3]。在此背景下,天然气管网向着大型化、复杂化、智能化的方向发展,天然气管道面临着能源革命与能源转型加快推进的新形势^[4]。人工智能技术的快速发展为智慧管网的变革带来了机遇,而瞬态仿真作为智慧管网系统的关键技术之一,通过模拟管网在各种动态条件下的运行状态,能够提升输送保障能力,降低建设运行成本^[5]。因此,有必要结合天然气管网瞬态仿真的特点,借助新兴的智能化方法,探索天然气管网瞬态仿真新思路,为提高天然气管网瞬态仿真的分析提供技术支撑。

天然气管道中天然气的瞬态物理特性的数学表征为满足质量守恒、动量守恒、能量守恒的一组偏微分方程组(PDEs)^[6-7]。由于PDEs的强非线性,无法给出解析解,需要特征线法^[8-9]、有限差分法^[10-11]、有限体积法^[12-13]等数值求解方法计算其数值解。近年来,机器学习在能源仿真领域取得了诸多成功的应用^[14-17]。Hadian等^[18]使用人工神经网络对大型天然气管网的水力稳态进行建模,使用布谷鸟优化算法训练网络权重,并将其与模型预测控制算法相结合进行压力控制。Su等^[19]基于深度学习算法,使用时间窗口和自动编码器预测天然气管网的运行状态,实现天然气管道对异常工况的仿真。Yin等^[20]借助代理模型的思想,结合BP神经网络和遗传算法,对天然气站管网进行数据驱动建模和控制。Fakhroleslam等^[21]通过提取时间序列特征,使用NARX网络对三角管网进行水力仿真。除了针对天然气管网的仿真,也有学者使用神经网络对管网设备进行仿真,Pourfard等^[22]使用两个支持向量机对压缩机的瞬态过程进行建模,分别用于预测与控制。Zhou等^[23]针对燃气轮机提出迁移学习框架,基于物理方程创建具有陡坡信号的强动态操作数据集,构建并训练基于编码器和解码器的特征相似性学习模型,实现特征自适应知识迁移。上述研究均通过纯数据驱动的模式,将神经网络作为天然气管道进出口的代理来实现,虽然在应用神经网络时具有较高的计算速度与精度,但是在神经网络的训练过程中需要标记大量的数据,这类数据的清洗工作需要较多的人为干预,并且管道仪表无法满足全线仿真所需沿线压力流量需求。此

外,泛化性能差也是纯数据驱动模式的另一大问题,天然气管道运行工况复杂多变,纯数据驱动的训练样本集难以覆盖所有运行工况^[24],导致超出训练样本工况的预测结果精度较低。

除了纯数据驱动的方式,还可以考虑将机理模型与神经网络结合,借助神经网络能够快速学习数据特征的优势,来加速机理模型求解或提高模型精度。Cui等^[25]利用神经网络代理复杂管网水力初始条件,将该初始条件带入机理模型以确保数值计算的收敛性。Yin等^[26]提出了天然气管网在线仿真框架,通过Kringing方法对模型参数进行代理,并使用NARX对不可避免的仿真误差修正。上述研究借助机器学习的强拟合能力,描述变量间高维复杂映射关系,本质上是神经网络服务于机理模型,仍然需要机理模型求解PDEs。最近,耦合物理信息(Physics-informed)来训练神经网络以求解PDEs成功应用在各个领域的仿真工作中^[27-29],该方法依赖于PDEs中的物理知识导出残差参与神经网络训练。在天然气管网领域也有学者涉猎,并应用于管道的设计优化当中^[30]。但是,当前针对PINN的研究在求解实际工程中的复杂动力系统时,往往需要结合额外的标签数据才能实现高精度和稳定的求解^[31],天然气管网的研究也仅针对特殊管网中的物理信息进行解释,缺少对管网系统建模的方法。

针对目前天然气管道仿真智能化方法存在的精度差、泛化性能差的问题,本文通过结合天然气管道运行数据,分析天然气管内流动机理,采用融合机理方程与数据驱动模型的方式,建立适用于任意天然气管网结构的PINN仿真模型。利用储运领域内的先验知识,将边界条件软约束(Boundary Soft-Constraint)转换为硬约束(Boundary Hard-Constraint),增加神经网络模型的可解释性,提高训练速度与仿真精度,在天然气管网智能化建设运行的趋势下,所提出的方法为融合机理与数据驱动的仿真应用提供了理论依据。

1 BHC-PINN 原理与模型搭建

为准确快速仿真天然气管道内气体的流动状态,耦合机理与数据模型的天然气管道仿真方法,需要建立深度学习模型。设计适当的神经网络结构实现对气体流动状态的快速求解,分析天然气管道内流体的流动模型,包括质量方程、动量方程、状态方程、管网连接方程、初始条件、边界条件等,借助自动微

分技术, 将各个机理方程转化为模型训练的损失项。此外, 将冗余观测数据与边界数据作为数据损失融入模型训练中, 从而构建天然气管道内嵌物理信息神经网络 (Physics-Informed Neural Network, PINN) 模型, 实现对天然气管网任意位置的流动状态估计。

1.1 天然气管网流动方程

天然气在管道中的一维等温流动满足质量守恒与动量守恒, 可以通过偏微分方程组 (PDEs) 对质量方程与动量方程进行准确的数学描述, 如:

$$\begin{cases} \frac{\partial \rho}{\partial t} + \frac{\partial \rho v}{\partial x} = 0 \\ \frac{\partial \rho v}{\partial t} + \frac{\partial \rho v^2}{\partial x} + \frac{\partial p}{\partial x} = -\frac{f}{2} \times \frac{\rho v |v|}{D} - g \rho \sin \theta \end{cases} \quad (1)$$

此外, 天然气作为可压缩气体, 满足实际气体状态方程:

$$p = Z_r \rho R_g T \quad (2)$$

式中 ρ 表示天然气实际密度, kg/m^3 ; t 表示时间, s ; v 表示流速, m/s ; x 表示距离, m ; p 表示压力, Pa ; f 表示摩阻系数; D 表示管道内径, m ; g 表示重力加速度, m/s^2 ; θ 表示管道倾角; Z_r 表示实际压缩因子; R_g 表示气体常数, $\text{J/(kg} \cdot \text{K)}$; T 表示气体温度, K 。其中, 在给定初始条件与边界条件下的任意 (x, t) 、 p 与 v 是方程组的待求解, ρ 可以通过式 (2) 求得。

在天然气管道系统中, 管网的入口与出口通常都设有压力计、流量计、密度计, 而管网的中间节点通常只配备压力计, 只有涉及贸易交接的分输站会配备流量计和密度计^[26]。由于密度计采样频率低, 无法作为瞬态仿真边界使用, 另外, 考虑到压缩因子计算复杂, 不易采用原始方程形式。因此, 需对原始方程做以下变换: ①将待求解变量转换为 p 与 Q ; ②将气体状态通过状态方程转换至标准工况。

当气体速度不接近音速时, 对流加速度项 $\partial \rho v^2 / \partial x$ 与方程中的其他项相比较小, 可以忽略^[32]。忽略沿程高差, 偏微分方程可以改写成关于气体压力与标准工况下流量的方程组^[33]:

$$\begin{cases} \frac{\partial p}{\partial t} + \frac{Z R_g T \rho_0}{A} \times \frac{\partial Q}{\partial x} = 0 \\ \frac{\partial Q}{\partial t} + \frac{A}{\rho_0} \times \frac{\partial p}{\partial x} + f \frac{Z R_g T \rho_0}{2DA} \times \frac{Q |Q|}{p} = 0 \end{cases} \quad (3)$$

式中 Z 表示标准状况下天然气压缩因子; ρ_0 表示标准状况下天然气密度, kg/m^3 ; Q 表示天然气标况流量, Nm^3/s ; A 表示管道截面面积, m^2 。

天然气管网的仿真通常需要入口压力、入口流量、出口压力、出口流量中的任意两个组合 (除入口

流量、出口流量组合) 作为边界条件, 此时如果其他变量处也存在仪表, 那么仪表产生的数据未在仿真过程中使用, 能够作为冗余数据修正模型。对于边界的选取, 则需要考虑天然气管道内流体状态的因果关系, 在天然气管道系统中, 气体自气源后经过压缩机进入管道, 即压缩机的增压作用使管道内流体状态发生变化, 同时压力是表征压缩机工作状态的重要参数, 因此, 入口处选用压力作为仿真边界; 天然气管道系统的下游可以认为是不同用气特征的用户, 即出口处的流量受用户用气需求的影响发生变化, 因此, 出口处选用流量作为仿真边界。

1.2 天然气管网 BHC-PINN 仿真模型

PINN 是一种基于物理信息训练的神经网络, 不仅像传统机器学习算法一样学习训练数据之间的映射关系, 还能学习输入的物理方程表达的数学关系。PINN 的基本思想是使用神经网络将 PDEs 的解 u 进行代理, 如式 (4) 所示, 其中 h 表示神经网络的不同隐含层, 那么通过自动微分原理, 神经网络同样可以对方程解的偏导数进行代理, 如式 (5) 所示。通过训练网络参数使得网络输出的偏导数 $\hat{u}'(x, t)$ 满足 PDEs 的等式关系, 就可以使网络不断逼近方程的解。

$$\hat{u}(x, t, \theta) = h_N h_{N-1} \cdots h_1 h_0(x, t) \quad (4)$$

$$\begin{cases} \frac{\partial \hat{u}}{\partial x} = \frac{\partial \hat{u}}{\partial h_N} \times \frac{\partial h_N}{\partial h_{N-1}} \cdots \frac{\partial h_1}{\partial h_0} \times \frac{\partial h_0}{\partial x} \\ \frac{\partial \hat{u}}{\partial t} = \frac{\partial \hat{u}}{\partial h_N} \times \frac{\partial h_N}{\partial h_{N-1}} \cdots \frac{\partial h_1}{\partial h_0} \times \frac{\partial h_0}{\partial t} \end{cases} \quad (5)$$

式中 $\hat{u}$ 表示神经网络的输出; θ 表示神经网络内部的可训练参数; h_N 表示神经网络第 N 层。

为了代理 1.1 节中偏微分方程组控制的管道内天然气流动状态, 设计天然气管网瞬态流动的 PINN 如图 1 所示。1 个神经网络对应 1 条天然气管道, x 表示管道的横向距离, m ; t 表示时间, s ; p 表示天然气在 (x, t) 处所受压力, Pa ; Q 表示天然气在 (x, t) 处的标况流量, m^3/s ; L_{pipe} 、 L_{node} 、 L_{data} 、 L_{IC} 、 L_{BC} 分别表示管道方程、拓扑结构、冗余数据、初始条件、边界条件对应的损失函数。模型具体训练过程为: ①分析天然气管道数据特征, 选择与流动状态强相关的变量作为仿真边界, 其余变量作为冗余信息; ②初步构建 PINN 框架, 建立满足物理方程、管网连接方程、初始边界条件、冗余数据的损失函数作为约束; ③搭建深度神经网络模型, 选择合适的网络结构; ④设置边界条件嵌入模式, 将损失函数整合作为网络参数优化的目标函数, 通过梯度下降算法, 将神经网络的输出逐渐逼近流动状态的真实解。




图 1 天然气管网仿真 PINN 框架图

1.2.1 天然气管道 PINN 模型结构

为了建立由 1.1 节描述的偏微分方程组控制的瞬态流的 PINN，首先将神经网络构造为 PDEs 解的代理。本文中使用了对大多数 PDEs 问题相对简单但足够充分的全连接前馈神经网络 (Fully Connected Neural Network, FCNN)^[34]。全连接前馈神经网络 $(x, t; \theta)$ 在这里是输入向量 (x, t) 和输出向量 (p, Q) 之间映射关系的代理，其中经过了 n 层隐含层对输入输出的非线性特点进行表征，其具体定义如：

$$\begin{cases} x = (x, t) \\ \hat{u} = N(x; \theta) \\ h_0(x) = W_0 x + b_0 \\ h_n(x) = \Phi[W_n h_{n-1}(x) + b_n] \\ h_N(x) = W_N h_{N-1}(x) + b_N \end{cases} \quad (6)$$

式中 N 表示神经网络； h_0 表示输入层； h_n 表示隐含层； h_N 表示输出层； W_n 表示第 n 层隐含层的权值矩阵； b_n 表示第 n 层隐含层的偏置向量； Φ 表示非线性的激活函数。

在设计网络结构时，可以采用两种全连接构造模式^[35]，一种为常规 PINN 的设计模式，如图 2-a 所示，其神经网络输入具有两个维度，对应 PDEs 方程的两个解 p 和 Q ，在该构造模式下，神经网络的输出由每个神经元的权值与偏置计算得出。另一种设计模式如图 2-b 所示，神经网络的输出是由多个输出为单个维度的 FCNN 组合而成，每一个 FCNN 的输出对应 PDEs 方程的一个解，将所有 FCNN 的解拼接后作为神经网络模型的输出，在该种构造模式下神经网络的每一个输出只决定其对应的 FCNN 中的神经元权值与偏置，不同输出之间的神经元互不影响。




图 2 全连接构造模式示意图

网络结构模式的选取需要考虑到管网仿真的边界特点与后续 PINN 硬约束的引入，在 1.1 节中的分析可以确定，天然气管网仿真边界通常是气源压力与用户流量，这意味着同样在边界位置的气源流量和用户压力需要通过仿真得出。在对边界进行约束时，仅需要对部分输出进行约束，即在一个输出不变的情况下对另一个输出进行训练。为保证在计算 p 与 Q 时，调用的可训练参数与映射过程中的参数没有交集，本文选用图 2-b 所示的设计模式。

传统深度神经网络训练求解 PDE 通常需要标记大量数据满足训练要求，即需要管道沿线各点的压力流量数据构成训练集，这就要求目标管道沿线都设置仪表来监测数据，但是天然气管道仅在进出口与个别中间阀室存在仪表数据，这导致神经网络难以学习气体中间过程蕴含的物理信息，使训练过拟合甚至违背物理规律。为了解决上述问题，本文提出天然气管网仿真 PINN 模型，该模型在训练过程中沿线各点压力流量数据通过机理信息进行约束，无需沿线压力流量的监测数据，降低了神经网络训练的数据量需求。

首先考虑天然气单管内的流动状态，定义单管 PINN 的输入为 (x, t) ，输出为 (p, Q) ，定义神经网络的仿真结果为 $N(x, t; \theta)$ ，根据第 1.1 节推导得到的质

量方程与动量方程,可以得到 PDEs 残差项为:

$$e_{ma} = \frac{\partial N_P}{\partial t} + \frac{Z R_g T \rho_0}{A} \times \frac{\partial N_Q}{\partial x} \quad (7)$$

$$e_{mo} = \frac{\partial N_Q}{\partial t} + \frac{A}{\rho_0} \times \frac{\partial N_P}{\partial x} + f \frac{Z R_g T \rho_0}{2DA} \times \frac{N_Q |N_Q|}{N_P} \quad (8)$$

式中下标 ma、mo 分别表示质量方程、动量方程;下标 P、Q 分别表示神经网络输出中的压力、流量,其偏导项可以通过式(5)进行计算。神经网络的优化目标为使 PDEs 残差项为 0,因此选用均方误差构造损失函数如:

$$L_{ma} = \frac{1}{N_{pipe}} \sum_{i=1}^{N_{pipe}} |e_{ma}(x_i, t_i)|^2 \quad (9)$$

$$L_{mo} = \frac{1}{N_{pipe}} \sum_{i=1}^{N_{pipe}} |e_{mo}(x_i, t_i)|^2 \quad (10)$$

式中 N_{pipe} 表示管道的样本数量, (x_i, t_i) 表示管道的第 i 个样本点,样本点可以通过等差或随机选取,所有管道的空间取样点分布可以不同,但是时间取样点必须相同。天然气管网中的所有管道需要满足两个 PDEs,因此构造管道损失如:

$$L_{pipe} = w_{ma} L_{i,ma} + w_{mo} L_{i,mo} \quad (11)$$

式中 w_{ma} 、 w_{mo} 分别表示质量方程、动量方程对应的权重参数。

对于原始 PINN 来说,需要构造边界条件损失与初始条件损失函数来使满足神经网络的训练满足初始边界条件,二者可以通过数据驱动得到残差函数如下:

$$e_{BC} = N(x_{BC}, t) - u_{BC} \quad (12)$$

$$e_{IC} = N(x, t_{IC}) - u_{IC} \quad (13)$$

式中 x_{BC} 表示边界空间坐标; u_{BC} 表示变量位于边界条件下的真实值; t_{IC} 表示初始时间坐标; u_{IC} 表示变量位于初始条件下的真实值。

据此构造初始条件损失如下:

$$L_{BC} = \frac{1}{N_{BC}} \sum_{i=1}^{N_{BC}} |e_{BC}(x_{i,BC}, t_{BC})|^2 \quad (14)$$

$$L_{IC} = \frac{1}{N_{IC}} \sum_{i=1}^{N_{IC}} |e_{IC}(x_{i,IC}, t_{i,IC})|^2 \quad (15)$$

式中 N_{BC} 表示边界条件的样本数量; N_{IC} 表示初始条件的样本数量。

此外,通过仪表冗余数据,可以构建基于网络输出结果与真实值之间的数据驱动的损失函数:

$$L_{data} = \frac{1}{N_{data}} \sum_{i=1}^{N_{data}} |N(x_i, t_i) - u_i|^2 \quad (16)$$

式中 N_{data} 表示冗余数据的样本数量。

因此,单管 PINN 的损失函数可以整理为:

$$L(\theta) = L_{pipe} + w_{BC} L_{BC} + w_{IC} L_{IC} + w_D L_{data} \quad (17)$$

式中 w_{BC} 、 w_{IC} 、 w_D 分别表示边界条件、初始条件、冗余数据对应的权重参数,该参数可以在训练过程中进行调整,以提高 PINN 的可训练性,神经网络的训练过程为最小化损失函数的优化过程,即:

$$\theta^* = \arg \min L(\theta) \quad (18)$$

1.2.2 天然气管道边界硬约束

1.2.1 节中所使用的边界约束模式为软约束模式,即将边界约束融合进边界损失中,作为目标函数的一部分使 PINN 模型学习边界数据,通过优化算法逐步让神经网络的输出逼近边界值。为提高训练效率,本文提出通过建立边界硬约束的模式,使神经网络的输出强制满足边界条件,称为 BHC-PINN (Boundary Hard-Constraint PINN)。为实现硬约束,需要在传统 PINN 的基础上进行改进,采用插值的思想构造如下函数:

$$u(x, t) = \lambda_B(x) \cdot B(t) + \lambda_P(x) \cdot \hat{u}(x, t; \theta) \quad (19)$$

式中 $u(x, t)$ 表示 BHC-PINN 的输出,在本文中表示 p 和 Q 组成的向量; $\hat{u}$ 表示神经网络的输出值; B 表示边界函数,输出为边界处的真实值,由于管网内边界位置确定,因此只与时间相关; $\lambda_P(x)$ 表示管道修正函数,遵循以下原则:当 x 位于边界处时, $\lambda_P(x)=0$, 否则 $\lambda_P(x) \neq 0$; $\lambda_B(x)$ 表示边界修正函数,遵循以下原则:当 x 位于边界处时, $\lambda_B(x)=0$ 。

通过构造如上形式,当 x 位于边界处时, BHC-PINN 的输出 $u(x, t)=B(t)$, 可以直接满足边界条件而无需将边界约束融合进目标函数。由于在神经网络训练过程中涉及求导操作,因此需要从自动微分角度讨论 $\lambda_P(x)$ 、 $\lambda_B(x)$ 的构造方式。

在采用硬约束对偏导数 $u'(x, t)$ 构造满足 PDEs 的等式关系时,需要通过复合函数求导来实现,即:

$$\frac{\partial u}{\partial x} = B^T \frac{\partial \lambda_B}{\partial x} + \lambda_P \frac{\partial \hat{u}}{\partial x} + \hat{u} \frac{\partial \lambda_P}{\partial x} \quad (20)$$

$$\frac{\partial u}{\partial t} = \lambda_B^T \frac{\partial B}{\partial t} + \lambda_P \frac{\partial \hat{u}}{\partial t} \quad (21)$$

因此,为得到导数值,只需保证 $\lambda_P(x)$ 和 $\lambda_B(x)$ 对 x 可导,本文构造如下函数:

$$\lambda_P(x) = \begin{cases} 1, & \neg(\Gamma_{in} \wedge \Gamma_{out}) \\ 1-x, & (\neg\Gamma_{in}) \wedge \Gamma_{out} \\ 1+x, & \Gamma_{in} \wedge (\neg\Gamma_{out}) \\ (1-x)(1+x), & \Gamma_{in} \wedge \Gamma_{out} \end{cases} \quad (22)$$

$$\lambda_B(x) = \begin{cases} 1, & \Gamma_{in} \wedge \Gamma_{out} \\ 1-x, & \Gamma_{in} \wedge (\neg \Gamma_{out}) \\ 1+x, & (\neg \Gamma_{in}) \wedge \Gamma_{out} \\ (1-x)(1+x), & \neg(\Gamma_{in} \wedge \Gamma_{out}) \end{cases} \quad (23)$$

式中 x 表示经过归一化后的神经网络的输入, 取值范围为 $[-1, 1]$; Γ_{in} 表示入口边界标识, 为 0 时表示入口边界未知, 为 1 时表示入口边界已知; Γ_{out} 表示出口边界标识, 取值含义同 Γ_{in} 。

1.2.3 天然气管网机理信息耦合

天然气管网可以分解为多个天然气管道, 各管道边界条件通过天然气管网拓扑结构中的节点连接, 因此天然气管网建模需考虑节点处的机理信息。首先, 天然气管网中的所有管道需要满足两个 PDEs, 因此构造管道损失如下:

$$L_{pipe} = \frac{1}{n_{pipe}} \sum_{i=1}^{n_{pipe}} (w_{ma} L_{i,ma} + w_{mo} L_{i,mo}) \quad (24)$$

式中 n_{pipe} 表示管网内的管道数量。

管网内部各个管道、边界之间的节点还需满足压力相等、质量守恒, 因此节点处可以定义残差项如:

$$e_{ij,P} = N_{i,P} - N_{j,P} \quad (25)$$

$$e_Q = \sum N_{in,Q} - \sum N_{out,Q} \quad (26)$$

式中下标 ij 表示与节点相连的编号为 i, j 的管道; 下标 in、out 分别表示流入、流出管道。

由于与节点相连的管道两两之间均需要满足压力相等, 因此对应的损失函数如:

$$L_P = \frac{1}{N_{node}} \sum_{k=1}^{N_{node}} \frac{2}{n_p(n_p-1)} \sum_{1 \leq i < j \leq N_p} |e_{ij,P}(t_k)|^2 \quad (27)$$

$$L_Q = \frac{1}{N_{node}} \sum_{k=1}^{N_{node}} |e_Q(t_k)|^2 \quad (28)$$

式中 n_p 表示与节点连接的管道数量。

天然气管网中所有节点都要满足两个残差函数, 因此构造节点损失如:

$$L_{node} = \frac{1}{n_{node}} \sum_{i=1}^{n_{node}} (w_P L_{i,P} + w_Q L_{i,Q}) \quad (29)$$

式中 n_{node} 表示管网内的节点数量; w_P 、 w_Q 分别表示节点压力和节点流量对应的权重参数。

边界条件已经在硬约束定义时满足, 因此不需要额外设置新的边界损失。由于传统 PINN 在训练过程中, 边界条件是作为损失函数的一部分参与训练的, 而神经网络的训练过程无法使损失函数完全收敛为 0, 这就导致传统 PINN 在已知边界处产生误差。但是, 边界硬约束通过改变网络结构的方式使 PINN 的输出

强制满足已知边界, 也就是说在边界处不会产生误差。

构造初始条件损失与仪表冗余数据的损失函数与单管相同, 均通过数据驱动的方式构建。因此, 对于任意天然气管网的 PINN 损失函数可以整理为:

$$L(\theta) = L_{pipe} + L_{node} + w_{IC} L_{IC} + w_D L_{data} \quad (30)$$

由于输入输出数据具有较大数量级差距, 如压力的数量级为 10^6 , 流量的数量级为 10^2 , 因此需要对神经网络的输入输出做归一化处理, 以减少量纲对神经网络训练的影响。经过初步数值实验, 本文采用最大最小值归一化的变体, 将神经网络的输入输出变量区间控制在 $[-1, 1]$ 之内, 具体公式如:

$$\tilde{x} = 2 \times \frac{x - x_{min}}{x_{max} - x_{min}} - 1 \quad (31)$$

式中 $\tilde{x}$ 表示归一化后的变量值, x 表示变量原始值, x_{min} 表示变量的最小值, x_{max} 表示变量最大值。

2 算例验证

本文以天然气管道仿真领域的经典管网进行验证^[32, 36-39], 其结构如图 3 所示, 该管网包括 3 条管道形成的一个环路、一个气源和两个用户。另外, 管道 2 上还设有一个中间阀室。管道的几何属性如表 1 所示, 两个用户的天然气需求呈现周期性震荡, 如图 4 所示, 气源的来气压力恒定为 5 MPa, 天然气在标准状况下的气体常数为 520 J/(kg · K), 密度为 0.72 kg/m³, 压缩因子为 0.996。仿真模型的时间步长为 60 s, 空间步长为 1 km, 总时间为 24 h。




图 3 天然气管网拓扑结构示意图

表 1 管道参数表

管道编号	管道长度/km	内径/mm	地面温度/°C	摩阻系数
1	90	600	20	0.01
2	80	600	20	0.01
3	100	600	20	0.01




图4 天然气管网用户用气需求图

为验证硬约束对仿真结果的影响,本文分别采用 PINN 模型和 BHC-PINN 模型进行仿真,两模型采用相同的网络参数,包括 4 层隐含层,节点设置为 [50, 50, 50, 50],模型输入为 2,输出为 1,激活函数采用 Tanh 函数。训练采用 Adam 优化器和 L-BFGS 优化器来评估总损失函数的收敛性,初始学习率设置为 0.01,每经过 500 次迭代学习率减小至原来的 1/10。在训练初期用 Adam 优化器进行广度寻优,在训练后期采用 L-BFGS 优化器进行深度寻优,该算法可以有效地解决大型非线性优化问题。

为评估所提出的模型,使用均方根误差 (Root Mean Square Error, *RMSE*)、均方根相对误差 (Root Mean Square Relative Error, *RMSRE*)、平均绝对误差 (Mean Absolute Error, *MAE*)、平均绝对百分比误差 (Mean Absolute Percentage Error, *MAPE*) 验证模型的准确性与有效性^[40]。

为对比仿真精度,采用商业天然气管网水力仿

真软件 Stoner Pipeline Simulator (简称 SPS) 进行仿真计算,参数设置、边界条件均按照 2.1 节中给定的设置,将仿真结果,并与神经网络结果进行对比。将仿真完成后的前 2 天出口压力作为冗余数据参与神经网络的训练,训练完成后选择入口流量、出口压力 (即节点 1、2 的压力) 作为判断依据,计算得出 PINN、BHC-PINN 的结果,并与仿真结果的误差对比 (表 2)。通过表 2 可知, PINN 流量的平均相对误差为 2.1%,压力的平均相对误差为 0.32%, BHC-PINN 流量的平均相对误差为 1.5%,压力的平均相对误差为 0.082%,两者结果均达到了现场应用误差要求。采用硬约束的 BHC-PINN 均优于未采用硬约束的 PINN 各项仿真误差,说明将边界数据直接嵌入神经网络的输出中对仿真结果具有很好的提升。对比两者之间的压力误差和流量误差,可以看出硬约束对压力的提升幅度大于对流量的提升幅度,其原因在于:当在节点 1 处施加压力硬约束时,管道 1 和管道 2 的入口压力通过节点压力平衡均可以直接确定,而在节点 2、3 施加流量硬约束时,该硬约束通过节点流量守恒公式来施加,与节点相连的管道流量无法直接确定,导致硬约束对于流量的提升幅度较压力不明显。

入口流量、出口压力随时间的变化如图 5 所示,纵向来看 PINN 和 BHC-PINN 使用冗余数据训练的出口压力在仿真初期结果都贴近仿真值,作为对比,入口流量的仿真在训练初期就产生了一定的误差。随着时间推移,冗余数据对神经网络训练的影响减弱,模型误差逐渐增大,但 PINN 的误差增大更加明显,说明 BHC-PINN 仿真结果稳定、准确。

为说明求解效率,对比 PINN 与 BHC-PINN 训练过程中的损失函数下降情况 (图 6),为方便比较,在满足迭代终止条件后继续进行训练至 2 500 轮次。

表2 PINN 与 BHC-PINN 结果与仿真结果间各误差对比表

误差指标	模型	入口流量误差	管道 1 出口压力误差	管道 2 出口压力误差	管道 3 出口压力误差	管道 3 入口压力误差
<i>RMSE</i>	PINN	3.021	17 351.754	23 143.644	13 311.277	15 017.362
	BHC-PINN	1.916	3 822.211	5 916.304	4 981.982	4 286.073
<i>RMSRE</i>	PINN	0.029	3.816×10^{-3}	4.970×10^{-3}	2.877×10^{-3}	3.209×10^{-3}
	BHC-PINN	0.021	0.8324×10^{-3}	1.271×10^{-3}	1.078×10^{-3}	0.9197×10^{-3}
<i>MAE</i>	PINN	9.128	3.011×10^8	5.356×10^8	1.772×10^8	2.255×10^8
	BHC-PINN	3.670	1.461×10^7	3.500×10^7	2.482×10^7	1.837×10^7
<i>MAPE</i>	PINN	2.095%	0.294%	0.450%	0.241%	0.277%
	BHC-PINN	1.497%	0.064%	0.093%	0.088%	0.082%




图 5 PINN 与 BHC-PINN 模型在入口流量、出口压力处的仿真值对比图




图 6 PINN 与 BHC-PINN 模型在训练过程收敛性对比图

PINN 与 BHC-PINN 模型都呈 S 型曲线下降, 最终趋于收敛。HBC-PINN 的初始损失值较高, 是由于神经网络在初始化过程中的随机性导致的。通过对比迭代终止条件, PINN 经过 1 768 次训练后迭代终止, BHC-PINN 在 910 次训练后终止, 在收敛效率上提高了 48.5%。通过对比训练时间, PINN 与 BHC-PINN 分别耗时 174.5 s 和 76.9 s, 在收敛速度上提高了 55.9%, 说明采用硬约束的 PINN 模型在仿真过程中兼具准确性和高效性。另外, BHC-PINN 平均单次训练时间也小于 PINN, 说明硬约束引入带来的额外的求导操作 [式 (20)、(21)] 不会增加训练负荷, 这提高了 PINN 在工程应用中的适用性。

在管网实际运行过程中, 管道的摩阻系数会随管道运行状况的不同而发生变化, 这一变化会体现在用户处压力的波动当中, 用户处压力过高会导致管道失效概率增大, 压力过低不满足用户需求, 因

此有必要讨论在不同摩阻系数下本方法的适用情况。

本文设置了 5 组摩阻系数, 取值范围为 $[0.006, 0.014]$, 将该摩阻系数应用到所有管道中, 分别采用 BHC-PINN 与商业软件 SPS 进行仿真。将 BHC-PINN 的管道 1 出口压力与管道 3 出口压力的平均值作为用户 1 处压力, 管道 2 出口压力与管道 3 入口压力的平均值作为用户 2 处的压力, 得到结果如图 7、表 3 所示。

从图 7 可以看出, 随着摩阻系数的增大, 用户压力逐渐减小, 且用户压力的波动幅度变大。由于用户处压力波动是由于用户处流量波动导致的, 说明在摩阻系数较大时, 用户处的低流量更容易导致压力不满足用户需求。从表 3 可以看出, 不同摩阻系数下 BHC-PINN 对压力的仿真结果基本都保持在 0.1% 以内, 证明该方法在不同工况下都具有较高的精度, 这能够在天然气管网的设计与运行阶段发挥一定的作用。

为进一步验证 BHC-PINN 管网各点的仿真效果, 选择中间阀室压力作为参照依据。阀室在天然气管网中起到了对管道的分节管控作用, 因此, 阀室压力的检测工作对于天然气管网来说是至关重要的, 虽然部分 RTU 阀室配备了压力、温度仪表, 但管道沿线分布着很多没有仪表的手动阀室。BHC-PINN 模型除了对气源、用户处的流量、压力进行仿真, 还能对中间阀室的压力进行仿真, 实现管网全线的安全管控。

如图 3 所示, 在管道 2 沿线设有一个中间阀室, 其仿真模型的仿真值不参与神经网络模型的训练, 将其地理位置作为 BHC-PINN 的输入, 可以得到中间阀室处的压力随时间的变化 (图 8)。可以看到, BHC-PINN 方法重构出的阀室压力时间变化情况与商业软件仿真结果基本一致, 虽然误差有随时间增大




图 7 不同摩阻系数下 BHC-PINN 模型在出口压力处的仿真值对比图

表 3 不同摩阻系数下 BHC-PINN 仿真结果平均相对误差表

摩阻系数	平均相对误差	
	用户 1 压力	用户 2 压力
0.006	0.047%	0.038%
0.008	0.070%	0.067%
0.010	0.049%	0.079%
0.012	0.079%	0.090%
0.014	0.101%	0.066%

表 4 管道 2 各处压力仿真结果间各误差对比表

不同位置压力	RMSE	RMSRE	MAE	MAPE
中间阀室	4 428.061	9.164×10^{-4}	1.961×10^7	0.079
管道出口	5 916.304	1.271×10^{-3}	3.500×10^7	0.093

管道 2 入口压力作为硬约束条件,出口压力没有约束,因此受硬约束影响沿线减弱的作用,导致 BHC-PINN 误差沿线增大。




图 8 BHC-PINN 模型在管道 2 中间阀室处压力仿真结果图

而增大的现象,但最大误差为 0.2%,完全满足天然气管网对中间阀室的管控需求。以仿真模型的值作为依据,探究 BHC-PINN 对管道中间节点压力的仿真性能(表 4),通过比较发现中间阀室压力的各项指标均优于出口压力,从硬约束的角度推测,由于

3 结论

针对当前 PINN 无法有效求解复杂动力系统问题,本文提出一种通过对边界条件进行硬约束的 PINN 训练模式,并给出适用于天然气管网的建模方法。通过数值案例与商业软件、原始 PINN 对比得到以下结论:

1) 分析天然气管道内流体流动机理,构造天然气管网仿真框架,将管道与拓扑结构的机理信息耦合进损失函数以提高模型可解释性,借助管网进出口冗余数据提高准确性。通过对比, PINN 流量的平均相对误差为 2.1%,压力的平均相对误差为 0.32%。

2) 通过建立边界硬约束的模式,使神经网络的输出强制满足边界条件,相较于 PINN,所提出的 BHC-PINN 仿真流量和压力的误差分别降低了 28.6% 和 74.4%,训练的效率和速度分别提高了 48.5% 和 55.9%,在不同摩阻系数下对用户处压力仿真误差在 0.1% 左右,提高了工程适用能力。

3) 基于硬约束的 PINN 能实现任意位置气体流动状态的观测,对于中间阀室压力的仿真最大误差

为 0.2%, 提高了管网的安全管控能力。通过对压力与流量的提升幅度、中间压力与出口压力的误差进行分析, 进一步从机理角度解释 BHC-PINN 模型训练的结果, 提高了模型的可解释性。

参 考 文 献

- [1] 丁建林, 西昕, 张对红. 能源安全战略下中国管道输送技术发展展望[J]. 油气储运, 2022, 41(6): 632-639.
DING Jianlin, XI Xin, ZHANG Duihong. Development and outlook of China's pipeline transportation technologies under energy security strategy[J]. Oil & Gas Storage and Transportation, 2022, 41(6): 632-639.
- [2] 黄维和, 宫敬. 天然气管道与管网多能融合技术展望[J]. 油气储运, 2023, 42(12): 1321-1328.
HUANG Weihe, GONG Jing. Prospect for the development of natural gas network and the multi-energy integration technology in pipeline networks[J]. Oil & Gas Storage and Transportation, 2023, 42(12): 1321-1328.
- [3] 孙青峰, 常维纯, 刘亮, 等. “全国一张网” 油气储运设施应急预案体系建设[J]. 油气储运, 2024, 43(2): 134-143.
SUN Qingfeng, CHANG Weichun, LIU Liang, et al. Development of an emergency response plan system for the "One Pipeline Network" of oil and gas storage and transportation facilities[J]. Oil & Gas Storage and Transportation, 2024, 43(2): 134-143.
- [4] 吴长春, 左丽丽. 关于中国智慧管道发展的认识与思考[J]. 油气储运, 2020, 39(4): 361-370.
WU Changchun, ZUO Lili. Understanding and thinking on the development of China's intelligent pipeline[J]. Oil & Gas Storage and Transportation, 2020, 39(4): 361-370.
- [5] 廖绮, 刘春颖, 杜渐, 等. 人工智能赋能油气管道运行管理的应用及展望[J]. 油气储运, 2024, 43(6): 601-613.
LIAO Qi, LIU Chunying, DU Jian, et al. Application and prospect of artificial intelligence in empowering the operation and management of oil and gas pipelines[J]. Oil & Gas Storage and Transportation, 2024, 43(6): 601-613.
- [6] 殷雄, 徐波, 刘天尧, 等. 考虑温压补偿的天然气管道自适应仿真方法[J]. 油气储运, 2024, 43(6): 710-719.
YIN Xiong, XU Bo, LIU Tianyao, et al. Self-adaptive simulation method for natural gas pipeline considering temperature and pressure compensations[J]. Oil & Gas Storage and Transportation, 2024, 43(6): 710-719.
- [7] JIANG Yunpeng, REN Zhouyang, YANG Xin, et al. A steady-state energy flow analysis method for integrated natural gas and power systems based on topology decoupling[J]. Applied Energy, 2022, 306: 118007.
- [8] CHEN Qian, XING Xiaokai, JIN Can, et al. A novel method for transient leakage flow rate calculation of gas transmission pipelines[J]. Journal of Natural Gas Science and Engineering, 2020, 77: 103261.
- [9] KESSAL M. Simplified numerical simulation of transients in gas networks[J]. Chemical Engineering Research and Design, 2000, 78(6): 925-931.
- [10] RACHFORD H H, DUPONT T. A fast, highly accurate means of modeling transient flow in gas pipeline systems by variational methods[J]. Society of Petroleum Engineers Journal, 1974, 14(2): 165-178.
- [11] ABARBANEL S, GOTTLIEB D, TURKEL E. Difference schemes with fourth order accuracy for hyperbolic equations[J]. SIAM Journal on Applied Mathematics, 1975, 29(2): 329-351.
- [12] FAN Di, GONG Jing, ZHANG Shengnan, et al. A transient composition tracking method for natural gas pipe networks[J]. Energy, 2021, 215: 119131.
- [13] SHI Guoyun, YU Weichao, WANG Kun, et al. Time-dependent economic risk analysis of the natural gas transmission pipeline system[J]. Process Safety and Environmental Protection, 2021, 146: 432-440.
- [14] BARUAH S, SINGH I V. A framework based on nonlinear FE simulations and artificial neural networks for estimating the thermal profile in arc welding[J]. Finite Elements in Analysis and Design, 2023, 226: 104024.
- [15] TAHIR F, ARSHAD M Y, SAEED M A, et al. Integrated process for simulation of gasification and chemical looping hydrogen production using Artificial Neural Network and machine learning validation[J]. Energy Conversion and Management, 2023, 296: 117702.
- [16] TSOUTSANIS E, QURESHI I, HESHAM M. Performance diagnostics of gas turbines operating under transient conditions based on dynamic engine model and artificial neural networks[J]. Engineering Applications of Artificial Intelligence, 2023, 126: 106936.
- [17] RAWAT S K, YASEEN M, PANT M, et al. Designing soft computing algorithms to study heat transfer simulation of ternary hybrid nanofluid flow between parallel plates in a parabolic trough solar collector: Case of artificial neural network and particle swarm optimization[J]. International Communications in Heat and Mass Transfer, 2023, 148: 107011.
- [18] HADIAN M, ALIAKBARI N, KARAMI M. Using artificial neural network predictive controller optimized with Cuckoo Algorithm for pressure tracking in gas distribution network[J]. Journal of Natural Gas Science and Engineering, 2015, 27: 1446-1454.
- [19] SU Huai, ZIO E, ZHANG Jinjun, et al. A systematic hybrid method for real-time prediction of system conditions in natural gas pipeline networks[J]. Journal of Natural Gas Science and Engineering, 2018, 57: 31-44.
- [20] YIN Xiong, WEN Kai, WU Yan, et al. A machine learning-based surrogate model for the rapid control of piping flow: Application to a natural gas flowmeter calibration system[J]. Journal of Natural Gas Science and Engineering, 2022, 98: 104384.

- [21] FAKHROLESLAM M, BOZORGMEHRY BOOZARJOMEHRY R, SAHLODIN A M, et al. Dynamic simulation of natural gas transmission pipeline systems through autoregressive neural networks[J]. *Industrial & Engineering Chemistry Research*, 2021, 60(27): 9851-9859.
- [22] POURFARD A, MOETAMEDZADEH H, MADOLIAT R, et al. Design of a neural network based predictive controller for natural gas pipelines in transient state[J]. *Journal of Natural Gas Science and Engineering*, 2019, 62: 275-293.
- [23] ZHOU Dengji, HAO Jiarui, HUANG Dawen, et al. Dynamic simulation of gas turbines via feature similarity-based transfer learning[J]. *Frontiers in Energy*, 2020, 14(4): 817-835.
- [24] 张海霖. 基于 CNN-LSTM 的天然气管道运行状态监测研究[D]. 重庆: 重庆大学, 2021.
- ZHANG Hailin. Research on monitoring of operation state for natural gas pipeline based on CNN-LSTM[D]. Chongqing: Chongqing University, 2021.
- [25] CUI Gaochen, JIA Qingshan, GUAN Xiaohong, et al. Data-driven computation of natural gas pipeline network hydraulics[J]. *Results in Control and Optimization*, 2020, 1: 100004.
- [26] YIN Xiong, WEN Kai, HUANG Weihe, et al. A high-accuracy online transient simulation framework of natural gas pipeline network by integrating physics-based and data-driven methods[J]. *Applied Energy*, 2023, 333: 120615.
- [27] ZHANG Xiaoping, ZHU Yan, WANG Jing, et al. GW-PINN: A deep learning algorithm for solving groundwater flow equations[J]. *Advances in Water Resources*, 2022, 165: 104243.
- [28] STRELOW E L, GERISCH A, LANG J, et al. Physics informed neural networks: A case study for gas transport problems[J]. *Journal of Computational Physics*, 2023, 481: 112041.
- [29] GU Weibin, PRIMATESTA S, RIZZO A. Physics-informed neural network for Quadrotor dynamical modeling[J]. *Robotics and Autonomous Systems*, 2024, 171: 104569.
- [30] ZHANG Chi, SHAFIEEZADEH A. Nested physics-informed neural network for analysis of transient flows in natural gas pipelines[J]. *Engineering Applications of Artificial Intelligence*, 2023, 122: 106073.
- [31] XIE Chiyu, DU Shuyi, WANG Jiulong, et al. Intelligent modeling with physics-informed machine learning for petroleum engineering problems[J]. *Advances in Geo-Energy Research*, 2023, 8(2): 71-75.
- [32] WANG Hai, LIU Xiaojing, ZHOU Weiguo. Transient flow simulation of municipal gas pipelines and networks using semi implicit finite volume method[J]. *Procedia Engineering*, 2011, 12: 217-223.
- [33] OSIADACZ A. Simulation of transient gas flows in networks[J]. *International Journal for Numerical Methods in Fluids*, 1984, 4(1): 13-24.
- [34] 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.
- [35] LU Lu, PESTOURIE R, YAO Wenjie, et al. Physics-informed neural networks with hard constraints for inverse design[J]. *SIAM Journal on Scientific Computing*, 2021, 43(6): B1105-B1132.
- [36] OSIADACZ A J. Simulation and analysis of gas networks[M]. New York: E. & F.N. Spon, 1987.
- [37] KE S L, TI H C. Transient analysis of isothermal gas flow in pipeline network[J]. *Chemical Engineering Journal*, 2000, 76(2): 169-177.
- [38] HAFSI Z, ELAOUD S, MISHRA M. A computational modelling of natural gas flow in looped network: Effect of upstream hydrogen injection on the structural integrity of gas pipelines[J]. *Journal of Natural Gas Science and Engineering*, 2019, 64: 107-117.
- [39] WEN Kai, JIAO Jianfeng, ZHAO Kang, et al. Rapid transient operation control method of natural gas pipeline networks based on user demand prediction[J]. *Energy*, 2023, 264: 126093.
- [40] 杜渐, 郑坚钦, 夏玉恒, 等. 耦合混油发展机理与数据修正的成品油管道混油浓度预测[J]. *油气储运*, 2024, 43(7): 796-808.
- DU Jian, ZHENG Jianqin, XIA Yuheng, et al. Prediction of mixed oil concentration in product oil pipeline coupling oil mixing mechanism and data correction[J]. *Oil & Gas Storage and Transportation*, 2024, 43(7): 796-808.

(修改回稿日期 2024-11-20 编辑 张晓雪)



本文
互动