

引用格式:胡慧芳,张世明,曹小朋,等.基于图神经网络的井间注采动态响应研究[J].油气地质与采收率,2023,30(4):130-136.
HU Huifang, ZHANG Shiming, CAO Xiaopeng, et al. Research on dynamic response of interwell injection-production based on graph neural network[J]. Petroleum Geology and Recovery Efficiency, 2023, 30(4): 130-136.

基于图神经网络的井间注采动态响应研究

胡慧芳^{1,2},张世明²,曹小朋²,郭奇²,王召旭³,黄朝琴³

(1.中国矿业大学(北京)煤炭资源与安全开采国家重点实验室,北京 100083; 2.中国石化胜利油田分公司勘探开发研究院,山东 东营 257015; 3.中国石油大学(华东)石油工程学院,山东 青岛 266580)

摘要:注采井间注采动态响应关系是油藏开发过程中的重要参数,对井间注采动态响应的正确评价可为油藏开发后期流场调控的工艺措施优化提供理论基础。注采井网可以等效成一种图结构,且井点间具有强相关性,为此基于图神经网络开展井间注采动态响应研究。通过图注意力网络结合多个时间节点注水井的单位时间注水量变化量和生产井的单位时间产液量变化量,以及渗流物理过程信息中的井底压力和井位数据等参数,对生产井产液量进行预测并反向传播学习,进而定量表征不同时刻的井间注采动态响应关系。结果表明,采用的新方法适用于井数较多且开关井频繁的实际油藏,具有成本低、动静参数结合和适用性广的优点。

关键词:图神经网络;井间连通性;机器学习;注意力机制;注采动态响应

文章编号:1009-9603(2023)04-0130-07

DOI:10.13673/j.pgre.202208033

中图分类号:TE319

文献标识码:A

Research on dynamic response of interwell injection-production based on graph neural network

HU Huifang^{1,2}, ZHANG Shiming², CAO Xiaopeng², GUO Qi², WANG Zhaoxu³, HUANG Zhaoqin³

(1.State Key Laboratory of Coal Resources and Safe Mining, China University of Mining and Technology-Beijing, Beijing City, 100083, China; 2.Exploration and Development Research Institute, Shengli Oilfield Company, SINOPEC, Dongying City, Shandong Province, 257015, China; 3.School of Petroleum Engineering, China University of Petroleum (East China), Qingdao City, Shandong Province, 266580, China)

Abstract: The dynamic response of interwell injection-production in injection and production wells is an important parameter in the process of reservoir development. The correct evaluation of the dynamic response of interwell injection-production can provide a theoretical basis for optimizing process measures of flow field control in the later stage of reservoir development. Injection-production well pattern can be equivalent to a graph structure, and there is a strong correlation between well points. Therefore, the dynamic response of interwell injection-production is studied based on the graph neural network. The fluid production of producing wells is predicted, and backpropagation learning is carried out, so as to quantitatively characterize the dynamic response relationship of interwell injection-production at different times based on the graph attention network, the variation amount of water injection per unit time in injection wells, the variation amount of liquid production per unit time in producing wells at multiple time nodes, and the parameters such as bottom hole pressure and well location data in the information of physical flow process. The results show that the new method is suitable for the actual reservoir with a large number of wells and frequent well opening and shutting operations. The method has the advantages of low cost and has combined dynamic and static parameters, so it can be widely applied.

Key words: graph neural network; interwell connectivity; machine learning; attention mechanism; dynamic response of injection-production

井间注采动态响应研究对油藏开发具有重要意义,可以为识别优势流动通道、制定流场调控方

收稿日期:2022-08-25。

作者简介:胡慧芳(1979—),女,山东东营人,高级工程师,硕士,从事油气田开发研究。E-mail:huhuifang600.slyt@sinopec.com。

基金项目:中国石化大数据前瞻项目“基于大数据的水驱油藏流场调控优化研究”(20191115200418146)。

案以及注水优化调整等方面的工作提供依据。目前对于井间注采动态响应的研究主要从静态连通性和注采动态响应2个方面来开展,其中静态连通性分析以测井曲线对比法和油藏参数对比法为主。测井曲线对比法是通过选取合适的测井曲线类型,将其在不同井的曲线形态进行对比分析,从而判断目标井组的连通情况^[1-3]。油藏参数对比法是将目标井组的组分、原油密度等进行对比来判断连通情况^[4]。但井间静态连通性分析方法不能真实反映井间流体的连通性。井间注采动态响应的研究方法主要有试井分析^[5]、示踪剂技术分析^[6-7]、数值模拟^[8]、统计分析^[9-10]、人工神经网络^[11]和卷积神经网络^[12]等。试井分析方法分为脉冲试井和干扰试井,通过改变某口井的注水量或产液量,然后观察该井周围其他井的数据变化,以此来分析该井与周围其他井的连通情况,其在实施时会影响油田完成生产计划。示踪剂技术分析有示踪剂配伍性和环保的要求且费时费力,不适合大规模应用。数值模拟方法需要油田具有完备的动静态资料,计算量大且由于地质模型的不确定性结果可能存在问题。统计分析方法以灰色关联度分析为主,通过对不同参数随时间的变化量进行分析,需对原数据进行无量纲处理,其计算结果取决于无量纲处理的方式。人工神经网络方法的结果未考虑井距、渗透率等参数,且具有全局相关的情况,缺乏可靠性。卷积神经网络方法通过对渗透率进行反演来体现不同井之间的连通关系,其在实际油藏中多口井存在相互影响的情况下应用效果尚未可知。

图是一种常见的数据结构,通常由顶点和边2个要素构成。由若干给定的点及连接两点的线所构成的图可用来描述某些事物之间的特定关系,很多领域都具有图结构式的数据,且已得到了广泛应用。图神经网络(Graph Neural Networks, GNN)模型在提取数据的关键复杂特征、挖掘深层次有效拓扑信息以及实现对海量数据的快速处理等方面^[13],例如预测化学分子特性^[14]、文本关系提取^[15-16]、图形图像结构推理^[17-18]、社交网络的节点聚类 and 链路预测^[19]、缺失信息的网络补全^[20]以及药物的相互作用预测^[21]等,均显示了其较强的可靠性。同时井间注采动态响应关系是受井间储层物性、生产制度、井网结构等时间和空间特征参数共同影响的。为此,笔者利用图神经网络方法,以井点为节点,以井网结构为图神经网络的图结构,建立产液量预测模型,进而反演井间注采响应关系。

1 图神经网络模型

2005年GORI等首次提出图神经网络概念^[22],2008年SCARSELLI等进一步定义了图神经网络的理论基础^[23]。

1.1 基本原理

在一个图中,每个节点都由自身特征和与其相关联的节点特征来定义。图神经网络的目标是学习一个包含每个节点的邻居信息的状态向量 \mathbf{h}_v 。状态向量 \mathbf{h}_v 可用于生成输出向量 \mathbf{o}_v ,如节点标签。设 f 为一个局部传递函数,其被所有节点共享,并根据输入邻居信息不断更新节点状态。设 g 为一个局部输出函数。将状态向量和输出向量分别定义为:

$$\mathbf{h}_v = f(\mathbf{x}_v, \mathbf{x}_{co[v]}, \mathbf{h}_{ne[v]}, \mathbf{x}_{ne[v]}) \quad (1)$$

$$\mathbf{o}_v = g(\mathbf{h}_v, \mathbf{x}_v) \quad (2)$$

通过叠加所有状态向量、所有的输出向量、所有的特征向量和所有的节点特征而得到的向量,将(1)和(2)式进一步表示为:

$$\mathbf{H} = F(\mathbf{H}, \mathbf{X}) \quad (3)$$

$$\mathbf{O} = G(\mathbf{H}, \mathbf{X}_N) \quad (4)$$

图神经网络使用经典的迭代法来计算状态向量,其表达式为:

$$\mathbf{H}^{t+1} = F(\mathbf{H}^t, \mathbf{X}) \quad (5)$$

对于任意初始值 $\mathbf{H}(0)$, (5)式以指数形式快速收敛到(3)式的解,利用目标节点信息进行指导,损失函数表达式为:

$$loss = \frac{1}{P} \sum_{i=1}^P (tw_i - pv_i)^2 \quad (6)$$

图神经网络学习是以梯度下降法为基础,其具体步骤包括:①状态向量 \mathbf{h}_v^t 是由(1)式迭代更新 t 个轮次,直至接近(3)式的定点解 $\mathbf{H}(t) \approx \mathbf{H}$ 。②利用损失函数计算权重 \mathbf{W} 的梯度。③根据上一步计算的梯度对权重 \mathbf{W} 进行更新。

1.2 注意力机制

VELICKOVIC等提出了基于邻居节点注意力机制的图注意力网络(Graph Attention Network, GAT),通过邻居节点的特征对其指定不同的权重来处理复杂或者不规则结构的计算图,且在Cora, Citeseer和Pubmed引文网络数据集的基准测试中得到了业内最佳水平^[24]。

引入注意力机制来计算图神经网络中节点 j 的特征对节点 i 的重要性程度,首先通过一个权重矩阵 \mathbf{W} 将节点 i 的特征与节点 j 的特征进行增维,并将

形成的高维特征拼接在一起;再通过映射函数 $a(\cdot)$ 将拼接后的高维特征映射为一个实数,即非归一化注意力系数 e_{ij} ,其表达式为:

$$e_{ij} = a(\mathbf{Wh}_i, \mathbf{Wh}_j) \quad (7)$$

但由于与节点 i 相邻的不仅包含节点 j ,故在聚合邻居信息时需对每个节点的所有邻居的注意力进行归一化,采用Softmax函数得到归一化后的注意力系数 α_{ij} ,其表达式为:

$$\alpha_{ij} = \text{Softmax}_j(e_{ij}) = \frac{\exp(e_{ij})}{\sum_{k \in M_i} \exp(e_{ik})} \quad (8)$$

使用LeakyReLU非线性函数作为激活函数,完整的注意力表达式可改为:

$$\alpha_{ij} = \frac{\exp\{\text{LeakyReLU}[\mathbf{a}^T(\mathbf{Wh}_i, \mathbf{Wh}_j)]\}}{\sum_{k \in M_i} \exp\{\text{LeakyReLU}[\mathbf{a}^T(\mathbf{Wh}_i, \mathbf{Wh}_k)]\}} \quad (9)$$

2 模型构建与验证

2.1 模型构建

图神经网络模型将油藏中的注水井和生产井作为节点,建立从注水井节点到生产井节点的关系。由于开关井导致不同时间井网结构不同,图神经网络模型的图结构也需改变,因此每个时间点对应一个图结构,将所有时间点的图拼在一起共同训练。针对某一时间点,注水井节点输入特征包括多个时间节点的注水量在单位时间的变化量、多个时间节点的注水量、井底压力和井位数据;生产井节点输入特征包括多个时间节点的产液量在单位时间的变化量、下一时间节点的产液量、井底压力和井位数据。

在(8)式中目标节点 i 即为生产井,初始节点 j 为注水井, \mathbf{h}_i 则表示多个时间节点的产液量在单位时间的变化量, \mathbf{h}_j 则表示多个时间节点的注水量在单位时间的变化量,将两者进行拼接后经过多层全连接层得到非归一化注意力系数 e_{ij} ,隐藏层数量为7,每一层神经元个数为输入时间个数的2倍。对于井间注采动态响应的研究,考虑井底压力和井距的影响,同时为了加快收敛速度和提高准确度,对非归一化注意力系数 e_{ij} 进行处理,可表示为:

$$e'_{ij} = \frac{e_{ij} P_{ij}}{l_{ij}} \quad (10)$$

节点输出特征被定义为注意力机制下的邻居节点加权组合,从注采平衡出发,物理意义上可表

示为生产井节点的产液量等于与之相邻的注水井节点的注水量加权组合。但具体哪些天的注水对生产井起主要影响是未知的,此处将多个时间节点的注水量作为输入嵌入一个全连接神经网络使其在训练过程中自适应学习,输出为一个实数,作为对生产井起作用的注水量。将该注水量与归一化注意力系数 α_{ij} 相乘加权组合,输出结果即为下一时间的生产井节点产液量预测值,再采用均方差函数(MSE)将其与真实值进行误差计算然后反向传播训练神经网络,其中初始学习率设置为0.001,每训练200次学习率降为原来的0.1倍,直至误差在可接受范围内时终止训练。此时可以提取注意力权重与注水量的乘积作为连通系数,从而实现井间注采动态响应的定量分析。

2.2 模型验证

利用数值模拟软件建立概念模型进行测试,模拟区块尺寸为500 m×500 m,设置4口注水井(I1, I2, I3, I4)和1口生产井P1,其渗透率及井网分布如图1所示。在生产井P1与注水井I1和I4之间设置一条高渗透带以增强非均质性同时便于对比结果。区块地层压力为21 MPa,岩石压缩系数为 $6 \times 10^{-4} \text{ MPa}^{-1}$;地层水密度为 1 g/cm^3 ,黏度为 $0.55 \text{ mPa}\cdot\text{s}$,压缩系数为 $4.2 \times 10^{-4} \text{ MPa}^{-1}$;束缚水饱和度为0.2;原油密度为 0.85 g/cm^3 ,21 MPa压力下黏度为 $12 \text{ mPa}\cdot\text{s}$,残余油饱和度为0.18。由于高渗透带的存在,注水井I1和I4的注水速率显著高于注水井I2和I3(图2)。

本文研究数据包含产液速率、注水速率和压力等,由于单位和数量级的差异导致绝对数值大的数据在神经网络误差函数计算时占据了主导地位;同时未归一化的数据在梯度下降过程中,其收敛速度相对较慢,从而增加了模型训练时间。为此,在训练过程中,需对数据集进行预处理以消除不同数量级间的差异性,将数据归一化到统一取值范围内。

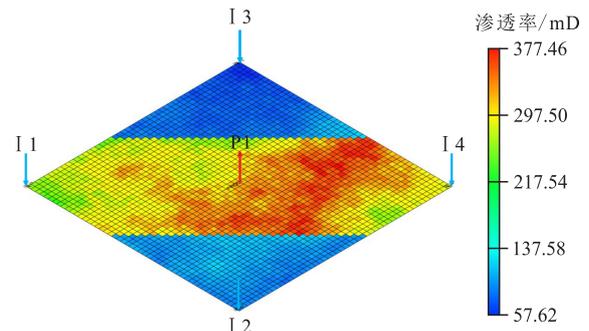


图1 概念模型渗透率及井网分布

Fig.1 Permeability and well pattern distribution of conceptual model

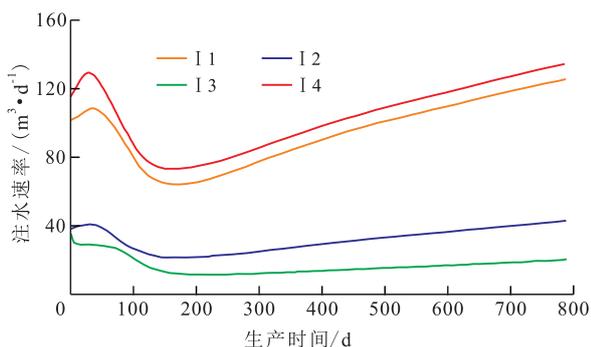


图2 各注水井注水速率随生产时间的变化

Fig.2 Variation of water injection rate in injection wells with working time

目前机器学习中归一化的方法主要有零均值归一化和最大最小值归一化,由于本文数据不是正态分布,故采用最大最小值归一化方法,将原数据映射到0~1。

将流线数值模拟^[25]和图神经网络方法得到的注采关系进行对比以验证其正确性。流线是质点在某一个时刻沿瞬时速度的切线所构成的曲线,可以描绘流体流向井筒的路径。流线数值模拟首先根据油藏流体性质以及初始化条件计算压力场与速度场;其次采用传播时间法进行流线追踪,确定流线位置;最后沿流线轨迹求解饱和度场。其生成的通量图可以形象的展示某一时刻注采井间产液量关系。

由图3可以看出,训练集与测试集的均方误差随训练轮次逐渐减小并趋于稳定,所以图神经网络模型训练效果较好。由表1可以看出,流线数值模拟和图神经网络方法均表现出高渗透带对生产井的影响,即注水井I1和I4对生产井的影响权重明显高于注水井I2和I3。2种方法中注水井对生产井影响权重的平均绝对误差为0.0114,平均相对误差为10.77%。但值得注意的是,由于注水井I3数据真实值较小,使得二者的相对误差较大,在不考虑注水井I3的情况下,2种方法中注水井对生产井影响权重的平均相对误差仅为2.10%,从而验证了

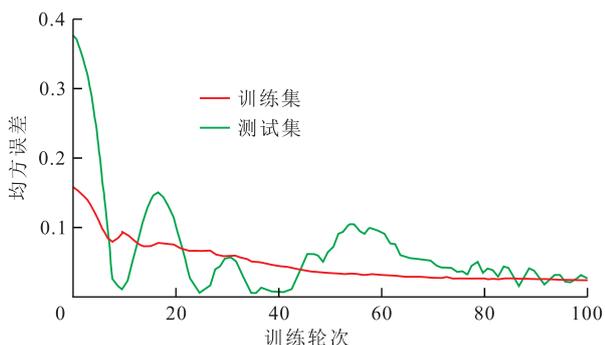


图3 均方误差随训练轮次的变化

Fig.3 Variation of mean square error with training batch

图神经网络方法的准确性。但实际油藏井数多、开关井频繁且资料匮乏,大部分油田仅具有注采数据、井底压力和井位数据等资料,无法提供整个油藏区块地质信息数据来满足流线数值模拟方法的需求,故运用本文提出的方法具有更广泛的适用性。

表1 流线数值模拟和图神经网络方法的注采关系对比
Table1 Comparison of injection-production relationships by streamlined numerical simulation and graph neural network methods

方法	注水井对生产井的影响权重			
	注水井 I1	注水井 I2	注水井 I3	注水井 I4
流线数值模拟	0.390 7	0.129 1	0.059 5	0.420 7
图神经网络	0.400 0	0.128 2	0.037 6	0.434 2

3 应用实例

选取某油田D区块作为目标区块,包含163口注水井和生产井(图4),目前处于高含水阶段,平均有效厚度为24.2 m,平均孔隙度为0.34,经历了天然能量开采、前期注水开采、聚合物注入开采和后期注水开采阶段,由射孔信息可知主要分为上、下两个层系,并根据其生产历史资料,选取重要时间节点进行分析。研究油藏井间注采动态响应关系时,注采井是否连接可以根据地质资料筛选连通情况或渗透率场图以渗透率低的区域为边界作为注水井的影响范围来进行判断。

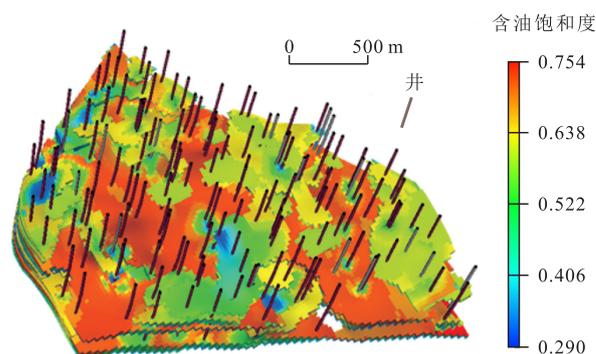


图4 目标区块地质建模及井网分布示意

Fig.4 Schematic diagram of geological modeling and well pattern distribution in target block

在油田开发阶段,一般根据剩余油分布和连通性信息调整注水井的注水速率以提高产油量;但在高含水阶段,含油饱和度较低时,连通性信息则更为重要。由本文方法预测的实际模型生产井产液量(图5)可知,预测值与真实值的平均相对误差仅为0.063。图6a为使用本文方法获得的油藏开发后

期井网调整前的主要注采关系,可根据该注采关系对井网进行调整;图6b为井网调整后的主要注采关系。为便于分析将注水井对生产井的影响权重划分为(0.3,0.7)和(0.7,1.0)两个区间,小于0.3的忽略不计。通过新方法得出的注采关系发现注水井向生产井输送过多水时,减少或关闭该注水井的注入及生产井的产出可以改变驱替水的流动方向,可使大量在高渗透通道中流动的注入水扩散到别处,以增加波及面积;同时根据注采关系可知,区块边缘和靠近注水井的未能波及的区域含油饱和度较高,可在该处增加新生产井。通过增加新生产井、开关原有井以及改变井的生产制度等流场调控,目标区块日产油量从552.79 m³/d增加至676.62 m³/d,原油增产率为22.40%,含水率由89.41%降至86.40%。由上可知,新方法既能准确预测生产井产液量,又能定量表征注采关系,进而指导了井网调

整并取得较好效果。

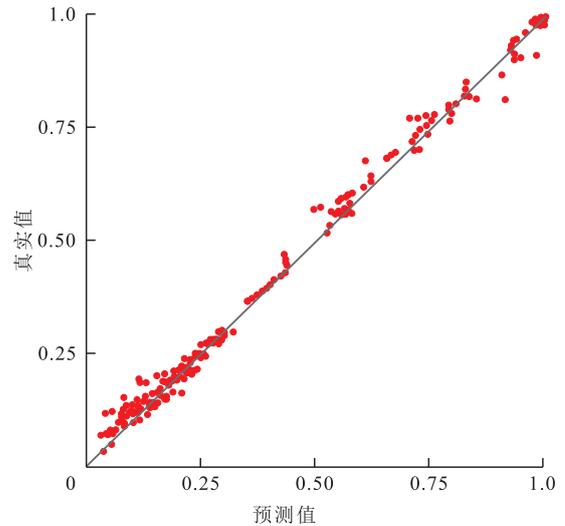


图5 实际模型生产井产液量预测结果

Fig.5 Predicted results of fluid production of producing wells in actual model

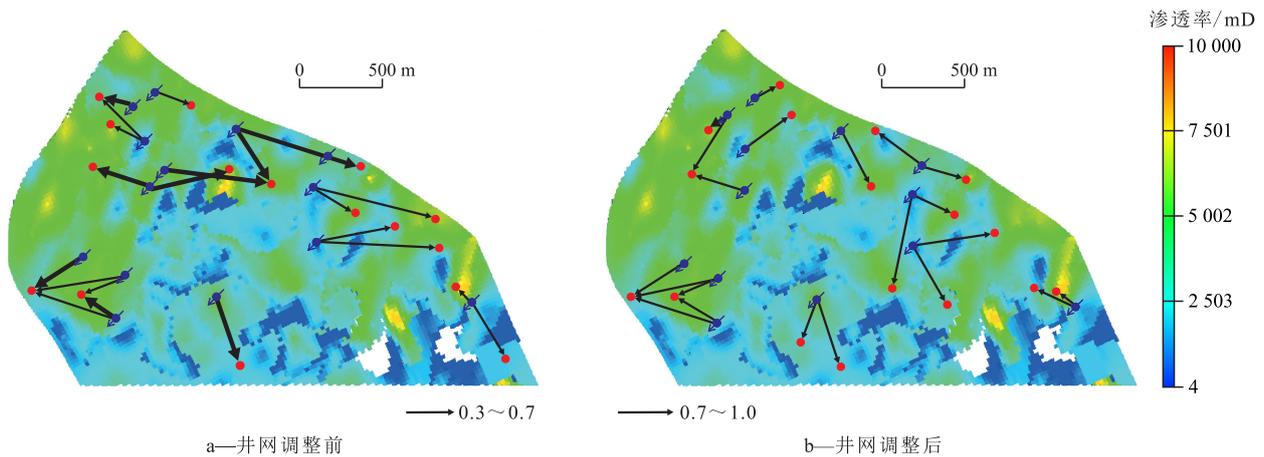


图6 油藏开发后期井网调整前后渗透率分布

Fig.6 Permeability distribution before and after adjusting well pattern in late stage of reservoir development

4 结论

基于图神经网络的井间注采动态响应方法结合井网分布以及生产动态数据,从油藏流体流动和注采平衡出发建立图神经网络模型,更加符合油藏实际生产情况,为目标区块流场调控的工艺措施优化提供了技术支持。实际油藏具有井数多、开关井频繁和资料匮乏等特点,难以满足数值模拟方法的需求。基于图神经网络的井间注采动态响应方法采用的生产资料易于获取,流线数值模拟和实际模型结果显示该方法能较好地反映出井间注采动态响应关系,具有很好的实用价值以及成本低、适用性广的优点。在下步研究中要充分利用油藏各种数据,考虑渗透率、孔隙度和流体黏度的影响,从而

使得研究结果更加接近实际油藏状况。

符号解释

- $a(\cdot)$ ——映射函数;
- \mathbf{a} ——权重向量;
- e ——非归一化注意力系数;
- e_{ij} ——节点*i*与节点*j*之间的非归一化注意力系数;
- e_{ik} ——节点*i*与节点*k*之间的非归一化注意力系数;
- e'_{ij} ——改进后节点*i*与节点*j*之间的非归一化注意力系数;
- $f(\cdot)$ ——局部传递函数;
- $F(\cdot)$ ——全局传递函数;
- $g(\cdot)$ ——局部输出函数;
- $G(\cdot)$ ——全局输出函数;
- \mathbf{h} ——状态向量;
- \mathbf{h}_i ——节点*i*的特征向量;

h_j ——节点 j 的特征向量;
 h_k ——节点 k 的特征向量;
 $h_{ne[v]}$ ——与节点 v 相邻节点的状态向量;
 h_v ——节点 v 的状态向量;
 H ——叠加所有状态构建的向量;
 H^t —— H 的第 t 次迭代;
 i ——图神经网络中的某个节点;
 j ——与节点 i 相邻的图神经网络中的某个节点;
 k ——与节点 i 相邻的图神经网络中的某个节点;
 l ——井距, m ;
 l_{ij} ——节点 i 与节点 j 之间的距离, m ;
 $loss$ ——损失函数;
 N ——所有节点集合;
 M_i ——与节点 i 相邻的所有节点集合;
 o_v ——输出向量;
 O ——叠加所有输出构建的向量;
 p ——井底压力, MPa ;
 p_{ij} ——节点 i 与节点 j 之间的压差, MPa ;
 pv ——预测值;
 pv_i ——节点输出的预测值;
 P ——监督节点的数目;
 t ——迭代次数;
 tv ——真实值;
 tw_i ——节点输出的真实值;
 v ——图神经网络节点;
 W ——权重;
 W ——权重矩阵;
 x ——特征向量;
 $x_{co[v]}$ ——与节点 v 相连的边的特征向量;
 $x_{ne[v]}$ ——与节点 v 相邻节点的特征向量;
 x_v ——节点 v 的特征向量;
 X ——所有的特征向量, 包含边和节点;
 X_N ——所有节点的特征向量;
 α_{ij} ——节点 i 与节点 j 之间的归一化后注意力系数。

参考文献

- [1] 钱志, 胡心红, 杨宏伟, 等. 综合利用多种测井曲线进行地层划分与对比[J]. 石油仪器, 2008, 22(5): 46-47, 52.
 QIAN Zhi, HU Xinhong, YANG Hongwei, et al. Strata classification and correlation by using various well logs[J]. Petroleum Instruments, 2008, 22(5): 46-47, 52.
- [2] 袁士宝, 宋佳, 任梓寒, 等. 基于机器学习的火驱注采井间连通性研究——以红浅1井区火驱先导试验区为例[J]. 中国海上油气, 2023, 35(2): 93-100.
 YUAN Shibao, SONG Jia, REN Zihan, et al. Study on connectivity between fire flooding injection and production wells based on machine learning: A case study of Hongqian1 fire flooding pilot test area[J]. China Offshore Oil and Gas, 2023, 35(2): 93-100.
- [3] 曾庆桥, 张亮, 刘萍, 等. 基于井间连通性的致密油藏注水井动态裂缝研究[J]. 断块油气田, 2022, 29(3): 383-389.
 ZENG Qingqiao, ZHANG Liang, LIU Ping, et al. Study on dynamic fracture of injection well based on inter-well connectivity in tight oil reservoir[J]. Fault-Block Oil and Gas Field, 2022, 29(3): 383-389.
- [4] 路琳琳, 杨作明, 孙贺东, 等. 动静态资料相结合的气井连通性分析——以克拉美丽气田火山岩气藏为例[J]. 天然气工业, 2012, 32(12): 58-61.
 LU Linlin, YANG Zuoming, SUN Hedong, et al. Analysis of gas well connectivity based on dynamic and static data: a case study from the volcanic gas reservoirs in the Kelameili Gas Field[J]. Natural Gas Industry, 2012, 32(12): 58-61.
- [5] 刘振宇, 曾昭英, 翟云芳, 等. 利用脉冲试井方法研究低渗透油藏的连通性[J]. 石油学报, 2003, 24(1): 73-77.
 LIU Zhenyu, ZENG Zhaoying, ZHAI Yunfang, et al. Study on connectivity of low-permeability reservoirs with pulse-testing method[J]. Acta Petrolei Sinica, 2003, 24(1): 73-77.
- [6] 张钊, 陈明强, 高永利. 应用示踪技术评价低渗透油藏油水井间连通关系[J]. 西安石油大学学报: 自然科学版, 2006, 21(3): 48-51.
 ZHANG Zhao, CHEN Mingqiang, GAO Yongli. Estimation of the connectivity between oil wells and water injection wells in low-permeability reservoir using tracer detection technique[J]. Journal of Xi'an Shiyou University: Natural Science Edition, 2006, 21(3): 48-51.
- [7] 申宝剑, 潘安阳, 张俊, 等. 一种页岩气井连通性评价的新型示踪剂应用研究[J]. 石油实验地质, 2021, 43(5): 855-861.
 SHEN Baojian, PAN Anyang, ZHANG Jun, et al. Evaluating the connectivity of shale gas wells by new rare element tracers[J]. Petroleum Geology & Experiment, 2021, 43(5): 855-861.
- [8] 徐慧, 林承焰, 郑元超, 等. 水下分流河道砂体油藏数值模拟研究[J]. 特种油气藏, 2013, 20(4): 58-61.
 XU Hui, LIN Chengyan, ZHENG Yuanchao, et al. Numerical simulation of subaqueous distributary channel sands[J]. Special Oil & Gas Reservoirs, 2013, 20(4): 58-61.
- [9] 冯其红, 陈存良, 杨光龙, 等. 利用注采数据研究岔15油田井间连通性[J]. 特种油气藏, 2014, 21(6): 87-89.
 FENG Qihong, CHEN Cunliang, YANG Guanglong, et al. Determination of inter-well connectivity in Cha-15 Oilfield using injection-production data[J]. Special Oil & Gas Reservoirs, 2014, 21(6): 87-89.
- [10] 张海锋, 刘世界, 冯毅, 等. 基于灰色关联度的井间动态连通性研究与应用[J]. 长江大学学报: 自然科学版, 2016, 13(16): 38-41.
 ZHANG Haifeng, LIU Shijie, FENG Yi, et al. Research and application of interwell dynamic connectivity based on gray correlation degree[J]. Journal of Yangtze University: Natural Science Edition, 2016, 13(16): 38-41.
- [11] 刘巍, 刘威, 谷建伟, 等. 利用卡尔曼滤波和人工神经网络相结合的油藏井间连通性研究[J]. 油气地质与采收率, 2020, 27(2): 118-124.
 LIU Wei, LIU Wei, GU Jianwei, et al. Research on interwell connectivity of oil reservoirs based on Kalman filter and artificial

- neural network[J]. *Petroleum Geology and Recovery Efficiency*, 2020, 27(2): 118-124.
- [12] 吴君达, 李治平, 孙妍, 等. 基于神经网络的剩余油分布预测及注采参数优化[J]. *油气地质与采收率*, 2020, 27(4): 85-93.
WU Junda, LI Zhiping, SUN Yan, et al. Neural network-based prediction of remaining oil distribution and optimization of injection-production parameters[J]. *Petroleum Geology and Recovery Efficiency*, 2020, 27(4): 85-93.
- [13] 白铂, 刘玉婷, 马驰骋, 等. 图神经网络[J]. *中国科学: 数学*, 2020, 50(3): 367-384.
BAI Bo, LIU Yuting, MA Chicheng, et al. Graph neural network[J]. *Scientia Sinica: Mathematica*, 2020, 50(3): 367-384.
- [14] DUVENAUD D K, MACLAURIN D, IPARRAGUIRRE J, et al. Convolutional networks on graphs for learning molecular fingerprints[C]. Montreal: Proceedings of the 28th Advances in Neural Information Processing Systems, 2015: 2 224-2 232.
- [15] MIWA M, BANSAL M. End-to-end relation extraction using LSTMs on sequences and tree structures[C]. Berlin: Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics, 2016: 1 105-1 116.
- [16] PENG Nanyun, POON H, QUIRK C, et al. Cross-sentence N-ary relation extraction with graph LSTMs[J]. *Transactions of the Association for Computational Linguistics*, 2017, 5: 101-115.
- [17] GARCIA V, BRUNA J. Few-shot learning with graph neural networks[C]. Vancouver: Proceedings of the International Conference on Learning Representations, 2018.
- [18] WANG Xiaolong, YE Yufei, GUPTA A. Zero-shot recognition via semantic embeddings and knowledge graphs[C]. Salt Lake City: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018.
- [19] ZHANG Muhan, CHEN Yixin. Link prediction based on graph neural networks[C]. Montreal: Proceedings of the 32nd International Conference on Neural Information Processing Systems, 2018: 5 171-5 181.
- [20] BOJCHEVSKI A, GÜNNEMANN S. Deep gaussian embedding of graphs: unsupervised inductive learning via ranking[C]. Vancouver: Proceedings of the International Conference on Learning Representations, 2018.
- [21] ZITNIK M, AGRAWAL M, LESKOVEC J. Modeling polypharmacy side effects with graph convolutional networks[J]. *Bioinformatics*, 2018, 34(13): 457-466.
- [22] GORI M, MONFARDINI G, SCARSELLI F. A new model for learning in graph domains[C]. Montreal: Proceedings of the IEEE International Joint Conference on Neural Networks, 2005.
- [23] SCARSELLI F, GORI M, TSOI A C, et al. The graph neural network model[J]. *IEEE Transactions on Neural Networks*, 2008, 20(1): 61-80.
- [24] VELICKOVIC P, CUCURULL G, CASANOVA A, et al. Graph attention networks[C]. Vancouver: Proceedings of the International Conference on Learning Representations, 2018.
- [25] 黄勇, 王业飞, 孙致学, 等. 基于流线模拟的高含水油田注水效率优化[J]. *西安石油大学学报: 自然科学版*, 2017, 32(2): 53-58.
HUANG Yong, WANG Yefei, SUN Zhixue, et al. Optimization of water injection efficiency based on streamline simulation in high water cut stage[J]. *Journal of Xi'an Shiyou University: Natural Science Edition*, 2017, 32(2): 53-58.

编辑 何青芳